



Sveučilište u Zagrebu

Fakultet organizacije i informatike

ANDRIJA BERNIK

**UVOĐENJE ELEMENATA RAČUNALNE IGRE U
ONLINE POUČAVANJE SADRŽAJA INFORMATIČKIH
NASTAVNIH PREDMETA**

DOKTORSKI RAD

Varaždin, 2017.

PODACI O DOKTORSKOM RADU

I. AUTOR

Ime i prezime	Andrija Bernik
Datum i mjesto rođenja	24.03.1985., Karlovac
Naziv fakulteta i datum diplomiranja na VII/I stupnju	Fakultet organizacije i informatike,
Naziv fakulteta i datum diplomiranja na VII/II stupnju	Fakultet organizacije i informatike
Sadašnje zaposlenje	Srednja škola u Maruševcu s pravom javnosti

II. DOKTORSKI RAD

Naslov	Uvođenje elemenata računalne igre u online poučavanje sadržaja informatičkih nastavnih predmeta
Broj stranica, slika, tabela, priloga, bibliografskih podataka	415 stranica, 87 slika, 229 tablica, 56 priloga, 194 bibliografskih referenci
Znanstveno područje i polje iz kojeg je postignut doktorat znanosti	Društvene znanosti / informacijske i komunikacijske znanosti / informacijski sustavi i informatologija
Mentori ili voditelji rada	Prof.dr.sc. Goran Bubaš, Prof.dr.sc. Danijel Radošević
Fakultet na kojem je obranjen doktorski rad	Fakultet organizacije i informatike
Oznaka i redni broj rada	135.

III. OCJENA I OBRANA

Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena tema	25. studeni 2014.
Datum predaje rada	13. lipnja 2017.
Datum sjednice Fakultetskog vijeća na kojoj je prihvaćena pozitivna ocjena rada	20. lipnja 2017.
Sastav povjerenstva koje je rad ocijenilo	Prof.dr.sc. Dragutin Kermek Prof.dr.sc. Goran Bubaš Prof.dr.sc. Danijel Radošević Izv.prof.dr.sc. Mihaela Banek Zorica Doc.dr.sc. Igor Balaban
Datum obrane doktorskog rada	07. srpnja 2017.
Sastav povjerenstva pred kojim je rad obranjen	Prof.dr.sc. Dragutin Kermek Izv.prof.dr.sc. Mihaela Banek Zorica Doc.dr.sc. Igor Balaban Doc.dr.sc. Dijana Plantak Vukovac, zamjenski član
Datum promocije	rujan 2017.



Sveučilište u Zagrebu

Fakultet organizacije i informatike

ANDRIJA BERNIK

**UVOĐENJE ELEMENATA RAČUNALNE IGRE U
ONLINE POUČAVANJE SADRŽAJA INFORMATIČKIH
NASTAVNIH PREDMETA**

DOKTORSKI RAD

Mentori:

Prof.dr.sc. Goran Bubaš, redoviti profesor
Prof.dr.sc. Danijel Radošević, redoviti profesor

Varaždin, 2017.



University of Zagreb

Faculty of Organization and Informatics

ANDRIJA BERNIK

**IMPLEMENTATION OF COMPUTER GAME
ELEMENTS INTO ONLINE TEACHING OF
INFORMATION TECHNOLOGY COURSES**

DOCTORAL THESIS

Varaždin, 2017.

ZAHVALA

Ovaj doktorski rad rezultat je niza aktivnosti koje su provođene od 2010. do 2012. godine kao dio studentskih obveza na doktorskom studiju Fakulteta organizacije i informatike. Od 2013. do 2014. godine provode se teorijska istraživanja, dok se od 2014. do 2015. provode empirijska istraživanja te se izrađuje popratna dokumentacija u okviru ove disertacije.

Za to vrijeme zahvalan sam svojoj obitelji, roditeljima i sestri, s kojima sam dijelio zanimljive trenutke, događaje i uspjehe na tom, iznimno poučnom, putu. Zahvalan sam i svojoj supruzi Sandi na pozitivnoj energiji i toleriranju brojnih sati koji su bili usmjereni u provođenje i pisanje ovog znanstvenoistraživačkog rada.

U vrijeme planiranja poslovnih aktivnosti profesor doc. dr. sc. Zvonimir Sabati utjecao je na moju odluku o upisu dokorskog studija. Od tada pa do trenutka pisanja zaključka zahvaljujem se profesoru Sabatiju na podršci i pomoći, bez koje bi ovaj put bio znatno teži. Zahvaljujem se i svojim mentorima, prof. dr. sc. Goranu Bubašu i prof. dr. sc. Danijelu Radoševiću, koji su me posljednje tri godine nadgledali i uvodili u znanstvenoistraživački rad koji započinje ovom doktorskom disertacijom. Naučio sam iznimno puno od Vas te Vam hvala na mogućnosti korištenja Vaših e-tečajeva, stručnoj podršci u pripremi teorijskog dijela kao i u provođenju empirijskog dijela istraživanja.

Zahvaljujem se svima koji su doprinijeli realizaciji ovog istraživanja i to doc. dr. sc. Dariju Čerepinku sa Sveučilišta Sjever, koji me poticao i pomagao u ključnim trenucima, te prof. dr. sc. Damiru Vusiću, prorektoru Sveučilišta Sjever, koji je odobrio moje istraživačke aktivnosti u okviru kolegija "3D modeliranje". Zahvaljujem se i studentima koji su sudjelovali u istraživanju te pokazali kako je promjena u hrvatskom obrazovnom sustavu moguća.

Andrija Bernik

PREDGOVOR

Elementi računalnih igara predstavljaju područje istraživanja koje se često spominje u poslovnim i drugim područjima koja nisu vezane uz računalne igre. Svaka se računalna igra može analizirati s obzirom na **dinamiku, mehaniku i estetiku** igre, a u obzir se uzimaju i komponente na temelju kojih je igra prikazana korisniku. Pojam koji se u znanstvenoj i stručnoj literaturi opisuje kao primjena elemenata računalne igre u području koje nije vezano za računalnu igru zove se **gemifikacija**, a on se koristi ovom radu. Dosadašnja istraživanja gemifikacije i gemificiranih sustava fokusirana su na **poslovne, pedagoške i psihološke utjecaje** na korisnike sustava. Brojni znanstvenici i sveučilišta pokazuju kako je utjecaj pozitivan, uz odličan odaziv i povratnu informaciju korisnika, te se u ovome radu naglasak stavlja na razmatranje **gemifikacije u kontekstu e-učenja**. S obzirom na to da je gemifikacija kao pojam i metodologija prihvaćena sredinom 2010. godine, govori se o novijem području istraživanja.

Gledajući s pedagoškog i psihološkog aspekta uvođenja elemenata računalnih igara u edukacijski sustav, brojni znanstveni radovi upućuju na pozitivan ishod učenja i razvijanje vještina kritičkog i problemski orijentiranog razmišljanja, osjećaja povezanosti i dublje razumijevanje teme. Gemificiranim pristupom **utječe se na ponašanje** za vrijeme učenja; potiče se **komunikacija, interakcija, kolaboracija** i trenutna povratna **informacija o statusu** uspjeha studenta, a neuspjehu se pristupa s ohrabrenjem i novim smjernicama za učenje. Iz navedenog razloga daje se osvrt na **opće shvaćanje** gemifikacije i njenih ključnih elemenata te **pedagoški i psihološki utjecaj** na korisnike s naglaskom na online edukaciju i Moodle LMS sustav (eng. *Learning Management System*). Moodle je izabran jer predstavlja jedan od **najkorištenijih sustava** otvorenog koda.

Na temelju navedenoga ova će disertacija kroz teorijsko i empirijsko istraživanje iskazati sljedeće: 1) pokazati i definirati **skup elemenata računalnih igara** koji su **pogodni i potrebni u edukacijskom sustavu**; 2) kreirati **konceptualan model** (eRIOOS) koji ujedinjuje sve moguće elemente računalnih igara te ih staviti u odnos s tradicionalnim online sustavima poučavanja; 3) **definirati način** na koji se postojeći **Moodle sustav proširuje u gemificirani sustav** s naglaskom na kolegije informatičkih sadržaja poučavanja; 4) pokazati **pozitivan učinak na motivaciju i ishode učenja** kod *eksperimentalne* skupine ispitanika koji će koristiti eksperimentalni online sustav kao osnovu za obrazovne aktivnosti unutar određenog kolegija.

SADRŽAJ

ZAHVALA	I
PREDGOVOR	II
SADRŽAJ	III
POPIS SLIKA	VII
POPIS TABLICA	IX
POPIS PRILOGA	XVIII
POPIS KRATICA	XIX
1. UVOD	1
1.1. Struktura doktorske disertacije	1
1.2. Definiranje problema istraživanja	3
1.3. Ciljevi i hipoteze istraživanja	6
1.4. Nacrt i metodologija istraživanja	9
1.4.1. Teorijsko istraživanje	9
1.4.2. Empirijsko istraživanje	9
1.5. Grafički prikaz istraživanja	11
2. PEDAGOŠKI I TEHNOLOŠKI ASPEKTI E-UČENJA	13
2.1. E-učenje	13
2.1.1. Definiranje e-učenja	13
2.1.2. Elementi e-učenja	21
2.1.2.1. Sustav za upravljanje učenjem (LMS)	21
2.1.2.2. Sadržaj e-tečaja	23
2.1.2.3. Suradnja u e-tečaju	24
2.1.3. Klasifikacija i vrste e-učenja	25
2.1.4. E-učenje u visokoškolskom obrazovanju	28
2.1.5. Moodle sustav za upravljanje učenjem u obrazovanju	34
2.1.6. Aktivnosti i resursi prisutni u Moodle sustavu	36
2.1.7. Budući razvoj e-učenja	47
2.2. Pedagoški aspekti e-učenja	54
2.2.1. Pedagoške teorije i e-učenje	54
2.2.1.1. Bihevizizam	54

2.2.1.2. Kognitivizam	55
2.2.1.3. Konstruktivizam	57
2.2.1.4. Konektivizam	60
2.2.2. Teorije i vrste procjene znanja	62
2.2.3. Ishodi učenja	65
3. GEMIFIKACIJA E-UČENJA	67
3.1. Pojam i teorijski opis gemifikacije e-učenja	67
3.2. Elementi i struktura gemifikacijskog pristupa	73
3.2.1. Elementi gemifikacije – mehanika i estetika računalnih igara	75
3.2.2. Elementi gemifikacije – dinamika računalnih igara	76
3.3. Tipovi igrača	79
3.4. Teorija tijeka	83
3.5. Pedagoški aspekti teorije tijeka	85
3.6. Uvođenje motivirajućih elemenata računalnih igara u obrazovni sustav	87
3.7. Utjecaj korištenja gemifikacije na nastavnike	97
3.8. Pedagoški i psihološki aspekt uvođenja gemifikacije u obrazovni sustav	101
3.9. Osnovni principi učenja pomoću elemenata računalnih igara	102
3.10. Gemifikacija kao "Peta teorija učenja"	104
3.11. Primjeri elemenata računalnih igara u obrazovnim sustavima	106
3.12. Postojeći priznati gemifikacijski modeli	108
4. DIZAJN E-TEČAJA	113
4.1. Analiza elemenata Moodle e-tečaja na visokoškolskim institucijama ...	113
4.2. Elementi računalnih igara primjenjivi na Moodle platformi	116
4.3. Opis elemenata računalnih igara odabranih za istraživanje	118
4.4. Izrada i implementacija idejnog rješenja	127
5. OPIS I OBILJEŽJA ISTRAŽIVANJA	137
5.1. Metodologija istraživanja	137
5.2. Ishodi učenja u e-tečajevima	141
5.2.1. Ishodi učenja za predistraživanje: "Osvjetljenje i renderiranje".....	141
5.2.2. Ishodi učenja za prvo glavno istraživanje: "Hrpa i stog"	143
5.2.3. Ishodi učenja za drugo glavno istraživanje: "Multimedija"	145
5.3. Ciljevi i hipoteze	147

5.4. Instrumentarij	149
5.4.1. Postupak izrade skala za mjerenje pojedinih konstrukata u anketnom upitniku	151
5.4.2. Primjer dijela anketnog upitnika motivacije i zadovoljstva	153
5.4.3. Predtest provjera znanja	154
5.4.4. Posttest provjera znanja	155
5.5. Ispitanici	156
5.6. Sadržaj e-tečajeva	158
5.6.1. Pilot e-tečaj "Osvjetljenje i renderiranje"	158
5.6.2. Eksperimentalni e-tečaj "Hrpa i stog"	159
5.6.3. Eksperimentalni e-tečaj "Multimedija"	160
5.7. Postupci i aktivnosti u pripremi provođenja istraživanja	163
6. REZULTATI ISTRAŽIVANJA	165
6.1. Predistraživanje: E-tečaj "Osvjetljenje i renderiranje"	166
6.1.1. Predtest analiza rezultata u provedenom predistraživanju	167
6.1.2. Posttest analiza rezultata u provedenom predistraživanju	170
6.1.3. Analiza rezultata anketnog upitnika u provedenom predistraživanju ..	179
6.1.4. Rasprava o rezultatima obrade podataka u predistraživanju	188
6.1.4.1. Predtest analiza rezultata u provedenom predistraživanju	188
6.1.4.2. Posttest analiza rezultata u provedenom predistraživanju	189
6.1.4.3. Unutarnja konzistentnost skala u provedenom predistraživanju ..	190
6.1.4.4. Razlika eksperimentalne i kontrolne skupine u odnosu na rezultate primjenom skala za procjenu	192
6.1.4.5. Zaključci imajući u vidu hipoteze i rezultate predistraživanja ...	195
6.2. Prvo glavno istraživanje: E-tečaj "Hrpa i stog"	205
6.2.1. Predtest analiza rezultata u provedenom prvom glavnom istraživanju	205
6.2.2. Posttest analiza rezultata u provedenom prvom glavnom istraživanju	214
6.2.3. Analiza rezultata anketnog upitnika u provedenom prvom glavnom istraživanju	228
6.2.4. Rasprava o rezultatima obrade podataka u prvom glavnom istraživanju	237
6.2.4.1. Predtest analiza rezultata u provedenom prvom glavnom istraživanju	237

6.2.4.2. Posttest analiza rezultata u provedenom prvom glavnom istraživanju	238
6.2.4.3. Unutarnja konzistentnost skala u provedenom prvom glavnom istraživanju	238
6.2.4.4. Razlika eksperimentalne i kontrolne skupine u odnosu na rezultate primjenom skala za procjenu	240
6.2.4.5. Zaključci imajući u vidu hipoteze i rezultate prvog glavnog istraživanja	243
6.3. Drugo glavno istraživanje: E-tečaj "Multimedija"	255
6.3.1. Predtest analiza rezultata u provedenom drugom glavnom istraživanju	256
6.3.2. Posttest analiza rezultata u provedenom drugom glavnom istraživanju	258
6.3.3. Analiza rezultata anketnog upitnika u provedenom drugom glavnom istraživanju	266
6.3.4. Rasprava o rezultatima obrade podataka u drugom glavnom istraživanju	275
6.3.4.1. Predtest analiza rezultata u provedenom drugom glavnom istraživanju	275
6.3.4.2. Posttest analiza rezultata u provedenom drugom glavnom istraživanju	276
6.3.4.3. Unutarnja konzistentnost skala u provedenom drugom glavnom istraživanju	276
6.3.4.4. Razlika eksperimentalne i kontrolne skupine u odnosu na rezultate primjenom skala za procjenu	278
6.3.4.5. Zaključci imajući u vidu hipoteze i rezultate drugog glavnog istraživanja	281
7. DISKUSIJA	290
7.1. Problemi i motivacija za provođenje istraživanja	290
7.2. Preliminarne istraživačke aktivnosti	292
7.3. Kratak osvrt i završna razmišljanja	294

8. ZAKLJUČAK	296
8.1. Metodologija i rezultati istraživanja	298
8.2. Ostali rezultati istraživanja	310
8.3. Ograničenja istraživanja	312
8.4. Smjernice za buduća istraživanja	314
LITERATURA	315
PRILOZI	328
PRILOG 1. Primjeri dokumenata istraživačkog rada	328
PRILOG 2. Primjeri svih pretest i posttest provjere znanja	332
PRILOG 3. Anketni upitnik motivacije i zadovoljstva iz predistraživanja	338
PRILOG 4. Anketni upitnik motivacije i zadovoljstva iz prvog i drugog glavnog istraživanja	346
PRILOG 5. Analiza rezultata obrade podataka u provedenom predistraživanju	353
PRILOG 6. Analiza rezultata obrade podataka u provedenom prvom glavnom istraživanju	363
PRILOG 7. Analiza rezultata obrade podataka u provedenom drugom glavnom istraživanju	378

POPIS SLIKA

Slika 1. Grafički prikaz istraživanja za potrebe ove doktorske disertacije	11
Slika 2. Fleksibilno učenje i prikaz potkategorija	18
Slika 3. Konceptualan okvir e-učenja	25
Slika 4. Pristup i korištenje servisa za e-učenje	28
Slika 5. Nacionalna politika e-učenja	30
Slika 6. Koristite li e-učenje u Vašoj organizaciji	31
Slika 7. Vrste e-učenja i njihova zastupljenost	31
Slika 8. Razlozi za upisivanjem e-tečaja	32
Slika 9. Usporedni prikaz LMS tehnologija od 2004. do 2016	35
Slika 10. Prikaz trendova pomoću Google Trends alata vezanih uz pojmove LMS i Moodle od 2004. do 2016.	35
Slika 11. Pregled ikona za Moodle aktivnosti i resurse	36
Slika 12. Grupirane aktivnosti i resursi Moodle sustava za e-učenje	46
Slika 13. Evolucija e-učenja	51
Slika 14. Položaj gemifikacije u odnosu na inovacijski ciklus	68
Slika 15. Klasifikacija gemifikacije	70
Slika 16. Osnovni elementi gemifikacijskog pristupa	74
Slika 17. Struktura gemifikacijskog pristupa	74
Slika 18. Zona tijeka i igračev put	77
Slika 19. Tipovi igrača i ikone kojima igrači mogu biti označeni u računalnim igrama	80
Slika 20. Odnosi između igrača – proširena podjela	82
Slika 21. Prikaz stanja tijeka	84
Slika 22. Prikaz zone razvoja studentskog znanja	86
Slika 23. Duolingo struktura i grafički prikaz sustava	106
Slika 24. Octalysis sustav i osnovni elementi	109
Slika 25. eRIOOS model prikazan kroz Octalysis Online alat	111
Slika 26. Primjer dijela sadržaja Moodle e-tečaja "X"	114
Slika 27. Primjer dijela sadržaja Moodle e-tečaja "Y"	115
Slika 28. Skrivena ilustracija iz eksperimentalnog e-tečaja	119
Slika 29. Pojednostavljeni model klasičnog e-tečaja	127
Slika 30. Konceptualan eRIOOS model gemificiranog e-tečaja za eksperimentalne skupine ispitanika	128
Slika 31. Idejno rješenje eRIOOS gemificiranog tečaja	133

Slika 32. Grafički prikaz gemificiranog e-tečaja	136
Slika 33. Prikaz strukture i dijela e-tečaja "Osvjetljenje i renderiranje" kolegija "3D"	156
Slika 34. Prikaz strukture i dijela e-tečaja "Hrpa i stog" kolegija "PRO"	158
Slika 35. Prikaz strukture i dijela e-tečaja "Multimedija" kolegija "RPK"	159
Slika 36. Grafički prikaz strukture empirijskog istraživanja ovog doktorskog rada	163
Slika 37. Dob ispitanika kolegija 3D modeliranje	164
Slika 38. Status ispitanika kolegija 3D modeliranje	164
Slika 39. Analiza težine pitanja iz pretest provjere znanja koji je korišten u predistraživanju	176
Slika 40. Analiza težine pitanja iz posttest provjere znanja koji je korišten u predistraživanju	176
Slika 41. Grafički prikaz analize odgovora svih ispitanika u provedenom predistraživanju prema učestalosti korištenja računala i Internet tehnologije	178
Slika 42. Grafički prikaz analize odgovora svih ispitanika u provedenom predistraživanju s obzirom na dužinu korištenja Internet tehnologije	180
Slika 43. Grafički prikaz analize odgovora svih ispitanika u provedenom predistraživanju s obzirom na korištenje tehnologije e-učenja	181
Slika 44. Grafički prikaz korištenja nastavnih i bonus materijala u kolegiju "3DM"	198
Slika 45. Dob ispitanika kolegija Programiranje 2	203
Slika 46. Status ispitanika kolegija Programiranje 2	203
Slika 47. Analiza težine pitanja iz pretesta koji je korišten u prvom glavnom istraživanju	225
Slika 48. Analiza težine pitanja iz posttesta koji je korišten u prvom glavnom istraživanju	225
Slika 49. Grafički prikaz analize odgovora svih ispitanika u provedenom prvom glavnom istraživanju prema učestalosti korištenja računala i Internet tehnologije	227
Slika 50. Grafički prikaz analize odgovora svih ispitanika u provedenom prvom glavnom istraživanju s obzirom na dužinu korištenja Internet tehnologije	229
Slika 51. Grafički prikaz analize odgovora svih ispitanika u provedenom prvom glavnom istraživanju s obzirom na korištenje tehnologije e-učenja	230
Slika 52. Grafički prikaz korištenja nastavnih i bonus materijala u kolegiju "PRO"	246
Slika 53. Dob ispitanika kolegija Računalom posredovana komunikacija	253
Slika 54. Status ispitanika kolegija Računalom posredovana komunikacija	253
Slika 55. Analiza težine pitanja iz pretesta koji je korišten u drugom glavnom istraživanju	263

Slika 56. Analiza težine pitanja iz posttesta koji je korišten u drugom glavnom istraživanju	263
Slika 57. Grafički prikaz analize odgovora svih ispitanika u provedenom drugom glavnom istraživanju prema učestalosti korištenja računala i Internet tehnologije	265
Slika 58. Grafički prikaz analize odgovora svih ispitanika u provedenom drugom glavnom istraživanju s obzirom na dužinu korištenja Internet tehnologije	267
Slika 59. Grafički prikaz analize odgovora svih ispitanika u provedenom drugom glavnom istraživanju s obzirom na korištenje tehnologije e-učenja	268
Slika 60. Grafički prikaz korištenja nastavnih i bonus materijala u kolegiju "RPK"	284
Slika 61. Ponovljeni prikaz korištenja nastavnih i bonus materijala u kolegiju "3DM"	298
Slika 62. Ponovljeni prikaz korištenja nastavnih i bonus materijala u kolegiju "PRO"	299
Slika 63. Ponovljeni prikaz korištenja nastavnih i bonus materijala u kolegiju "RPK"	300

POPIS TABLICA

Tablica 1. Prednosti e-učenja s aspekta nastavnika i studenata	19
Tablica 2. Koristi i mogući problemi e-tečaja	19
Tablica 3. Mogućnosti LMS sustava	23
Tablica 4. Odnos između elemenata e-učenja	24
Tablica 5. Primjeri alata za sinkronu i asinkronu komunikaciju	26
Tablica 6. Mogućnosti korištenja e-tečaja	27
Tablica 7. Klasifikacija obrazovnog procesa	27
Tablica 8. Broj obrazovnih institucija	29
Tablica 9. Profil obrazovnih institucija koje su sudjelovale u anketi za e-učenje	30
Tablica 10. Nastavna područja poučavana e-učenjem	32
Tablica 11. Aktivnosti i resursi Moodle sustava za e-učenje (prvi dio popisa)	37
Tablica 12. Aktivnosti i resursi Moodle sustava za e-učenje (drugi dio popisa)	38
Tablica 13. Međuodnos generacija weba i e-učenja	53
Tablica 14. Podržanost osnovnih principa konektivizma od strane Web 3.0 tehnologije	61
Tablica 15. Tablični prikaz teorija učenja	61
Tablica 16. Naziv i opis teorijskih modela koji mogu biti korišteni za oblikovanje i unapređenje procesa učenja	62
Tablica 17. Ishodi učenja s obzirom na sudionike u nastavnom procesu	66
Tablica 18. Bloomova klasifikacija kognitivnih vještina	66
Tablica 19. Elementi mehanike i estetike u gemifikacijskom sustavu	76
Tablica 20. Poveznica između mehanike računalnih igara i intrinzične motivacije	88
Tablica 21. Sažeti prikaz istraživačkih radova iz poglavlja 3.6. ove disertacije	95
Tablica 22. Utjecaj i primjena gemifikacije u visokoškolskom obrazovanju	97
Tablica 23. Tipovi korisnika i elementi računalnih igara pogodni za korištenje u e-učenju	99
Tablica 24. Elementi računalnih igara namijenjeni eksperimentalnom e-tečaju	116
Tablica 25. Moodle eksterni dodaci koji su potencijalno pogodni za korištenje u eksperimentalnom e-tečaju	117
Tablica 26. Usporedni prikaz elemenata računalnih igara koji su korišteni u sva tri istraživanja	126
Tablica 27. Autori i teme istraživanih skala koje su korištene za kreiranje ankete, odnosno novih mjernih skala	150
Tablica 28. Primjer anketnog upitnika - Zadovoljstvo (skala 2/15)	151
Tablica 29. Primjer anketnog upitnika - Zaokupljenost /uživljavanje (skala 5/15)	151
Tablica 30. Primjer anketnog upitnika - Postignuće učenja (skala 10/15)	151

Tablica 31. Primjer ispitnih pitanja predtesta (3D, PRO, RPK)	152
Tablica 32. Primjer ispitnih pitanja posttesta (3D, PRO, RPK)	153
Tablica 33. Broj prikupljenih upitnika i pisanih provjera znanja u provedenim istraživanjima	154
Tablica 34. Usporedni prikaz eksperimentalne i kontrolne grupe nakon predtesta za provjeru znanja	165
Tablica 35. Rezultati predtesta za sve ispitanike eksperimentalne (G1, G4) grupe	166
Tablica 36. Rezultati predtesta za sve ispitanike kontrolne (G2, G3) grupe	166
Tablica 37. Testiranje statističke značajnosti razlike metodom t-testa između rezultata predtesta eksperimentalne (G1) grupe i kontrolne (G2) grupe	166
Tablica 38. Testiranje statističke značajnosti razlike metodom t-testa između rezultata predtesta eksperimentalne (G4) grupe i kontrolne (G3) grupe	167
Tablica 39. Testiranje statističke značajnosti razlike metodom t-testa između rezultata predtesta svih ispitanika eksperimentalne (G1, G4) i kontrolne (G2, G3) grupe	167
Tablica 40. Usporedni prikaz eksperimentalne i kontrolne grupe nakon posttesta za provjeru znanja	168
Tablica 41. Rezultati posttesta za sve ispitanike eksperimentalne (G1, G4) grupe	169
Tablica 42. Rezultati posttesta za sve ispitanike kontrolne (G2, G3) grupe	169
Tablica 43. Testiranje statističke značajnosti razlike metodom t-testa između rezultata posttesta eksperimentalne (G1) grupe i kontrolne (G2) grupe	169
Tablica 44. Testiranje statističke značajnosti razlike metodom t-testa između rezultata posttesta eksperimentalne (G4) grupe i kontrolne (G3) grupe	170
Tablica 45. Testiranje statističke značajnosti razlike metodom t-testa između rezultata posttesta svih ispitanika eksperimentalne (G1, G4) i kontrolne (G2, G3) grupe	170
Tablica 46. Analiza otvorenog tipa pitanja posttest provjere znanja u predistraživanju	171
Tablica 47. Usporedni prikaz analize odgovora iz posttest provjere u predistraživanju	172
Tablica 48. Analiza težine pitanja u provedenom predtestu predistraživanja	174
Tablica 49. Analiza težine pitanja u provedenom posttestu predistraživanja	175
Tablica 50. Analiza odgovora svih ispitanika u provedenom predistraživanju prema učestalosti korištenja računala i Internet tehnologije	177
Tablica 51. Analiza odgovora svih ispitanika u provedenom predistraživanju s obzirom na dužinu korištenja Internet tehnologije	179
Tablica 52. Analiza odgovora svih ispitanika u provedenom predistraživanju s obzirom na korištenje tehnologije e-učenja	181

Tablica 53. Analiza skala druge cjeline anketnog upitnika u provedenom predistraživanju prije isključivanja neodgovarajućih čestica iz skala	182
Tablica 54. Analiza čestica treće cjeline anketnog upitnika (za čestice od 1 do 19) koja se odnosi na procjenu mišljenja ispitanika u provedenom predistraživanju	183
Tablica 55. Analiza čestica treće cjeline anketnog upitnika (za čestice od 20 do 41) koja se odnosi na utjecaj motivacijskih elemenata iz računalnih igara na učenje ispitanika u provedenom predistraživanju	184
Tablica 56. Analiza rezultata eksperimentalne i kontrolne grupe u provedenom predistraživanju prije isključivanja neodgovarajućih čestica iz skala	185
Tablica 57. Pregled isključenih čestica iz skala i daljnje obrade u provedenom predistraživanju	188
Tablica 58. Usporedni prikaz analize anketnog upitnika prije i nakon isključivanja neodgovarajućih čestica iz skala	189
Tablica 59. Analiza rezultata eksperimentalne i kontrolne grupe u provedenom predistraživanju nakon korekcije svih skala	190
Tablica 60. Analiza čestica treće cjeline anketnog upitnika (za čestice od 1 do 19) koja se odnosi na procjenu mišljenja ispitanika u provedenom predistraživanju	191
Tablica 61. Analiza čestica treće cjeline anketnog upitnika (za čestice od 20 do 41) koja se odnosi na utjecaj motivacijskih elemenata iz računalnih igara na učenje ispitanika u provedenom predistraživanju	192
Tablica 62. Testiranje statističke značajnosti razlike metodom t-testa između prosječnih rezultata odgovora na sve čestice treće cjeline anketnog upitnika	193
Tablica 63. Testiranje statističke značajnosti razlike metodom t-testa između prosječnih rezultata odgovora druge cjeline nakon korekcije anketnog upitnika	194
Tablica 64. Izvještaj o aktivnosti eksperimentalne i kontrolne grupe polaznika	196
Tablica 65. Usporedni prikaz korištenja nastavnih i bonus materijala u kolegiju "3DM"	198
Tablica 66. Usporedni prikaz testiranja statističke značajnosti razlike metodom t-testa između rezultata predtesta i rezultata posttesta kod svih ispitanika eksperimentalne (G1, G4) i kontrolne (G2, G3) grupe	200
Tablica 67. Skraćeni prikaz analize odgovora iz posttest provjere predistraživanja	202
Tablica 68. Usporedni prikaz eksperimentalnih grupa nakon predtesta za provjeru znanja	204
Tablica 69. Usporedni prikaz kontrolnih grupa nakon predtesta za provjeru znanja	206
Tablica 70. Rezultati predtesta za sve ispitanike eksperimentalne grupe	208
Tablica 71. Rezultati predtesta za sve ispitanike kontrolne grupe	208

Tablica 72. Testiranje statističke značajnosti razlike metodom t-testa između rezultata predtesta eksperimentalne (G2) grupe i kontrolne (G8) grupe	208
Tablica 73. Testiranje statističke značajnosti razlike metodom t-testa između rezultata predtesta eksperimentalne (G3) grupe i kontrolne (G9) grupe	209
Tablica 74. Testiranje statističke značajnosti razlike metodom t-testa između rezultata predtesta eksperimentalne (G5) grupe i kontrolne (G13) grupe	209
Tablica 75. Testiranje statističke značajnosti razlike metodom t-testa između rezultata predtesta eksperimentalne (G7) grupe i kontrolne (G4) grupe	209
Tablica 76. Testiranje statističke značajnosti razlike metodom t-testa između rezultata predtesta eksperimentalne (G11) grupe i kontrolne (G10) grupe	210
Tablica 77. Testiranje statističke značajnosti razlike metodom t-testa između rezultata predtesta eksperimentalne (G12) grupe i kontrolne (G1) grupe	210
Tablica 78. Testiranje statističke značajnosti razlike metodom t-testa između rezultata predtesta eksperimentalne (G14) grupe i kontrolne (G6) grupe	210
Tablica 79. Usporedni prikaz analize bodova između ispitanika eksperimentalne i kontrolne grupe polaznika u provedenoj predtest provjeri znanja	211
Tablica 80. Testiranje statističke značajnosti razlike metodom t-testa između rezultata predtesta svih ispitanika eksperimentalne (G _E) i kontrolne (G _K) grupe	211
Tablica 81. Usporedni prikaz eksperimentalnih grupa nakon posttesta za provjeru znanja	212
Tablica 82. Usporedni prikaz kontrolnih grupa nakon posttesta za provjeru znanja	214
Tablica 83. Rezultati posttesta za sve ispitanike eksperimentalne grupe	216
Tablica 84. Rezultati posttesta za sve ispitanike kontrolne grupe	216
Tablica 85. Testiranje statističke značajnosti razlike metodom t-testa između rezultata posttesta eksperimentalne (G2) grupe i kontrolne (G8) grupe	216
Tablica 86. Testiranje statističke značajnosti razlike metodom t-testa između rezultata posttesta eksperimentalne (G3) grupe i kontrolne (G9) grupe	217
Tablica 87. Testiranje statističke značajnosti razlike metodom t-testa između rezultata posttesta eksperimentalne (G5) grupe i kontrolne (G13) grupe	217
Tablica 88. Testiranje statističke značajnosti razlike metodom t-testa između rezultata posttesta eksperimentalne (G7) grupe i kontrolne (G4) grupe	217
Tablica 89. Testiranje statističke značajnosti razlike metodom t-testa između rezultata posttesta eksperimentalne (G11) grupe i kontrolne (G10) grupe	218

Tablica 90. Testiranje statističke značajnosti razlike metodom t-testa između rezultata posttesta eksperimentalne (G12) grupe i kontrolne (G1) grupe	218
Tablica 91. Testiranje statističke značajnosti razlike metodom t-testa između rezultata posttesta eksperimentalne (G14) grupe i kontrolne (G6) grupe	218
Tablica 92. Testiranje statističke značajnosti razlike metodom t-testa između rezultata posttesta svih ispitanika eksperimentalne (G _E) i kontrolne (G _K) grupe	219
Tablica 93. Analiza otvorenog tipa pitanja posttest provjere u prvom glavnom istraživanju	220
Tablica 94. Usporedni prikaz analize odgovora provedenog posttesta prvog glavnog istraživanja	221
Tablica 95. Analiza težine pitanja u provedenom predtestu prvog glavnog istraživanja	223
Tablica 96. Analiza težine pitanja u provedenom posttestu prvog glavnog istraživanja	224
Tablica 97. Analiza odgovora svih ispitanika u provedenom prvom glavnom istraživanju prema učestalosti korištenja računala i Internet tehnologije	226
Tablica 98. Analiza odgovora svih ispitanika u provedenom prvom glavnom istraživanju s obzirom na dužinu korištenja Internet tehnologije	228
Tablica 99. Analiza odgovora svih ispitanika u provedenom prvom glavnom istraživanju s obzirom na korištenje tehnologije e-učenja	230
Tablica 100. Analiza skala druge cjeline anketnog upitnika u provedenom prvom glavnom istraživanju prije isključivanja neodgovarajućih čestica iz skala	231
Tablica 101. Analiza čestica treće cjeline anketnog upitnika (za čestice od 1 do 19) koja se odnosi na procjenu mišljenja ispitanika u provedenom prvom glavnom istraživanju ..	232
Tablica 102. Analiza čestica treće cjeline anketnog upitnika (za čestice od 20 do 41) koja se odnosi na utjecaj motivacijskih elemenata iz računalnih igara na učenje ispitanika u provedenom prvom glavnom istraživanju	233
Tablica 103. Analiza rezultata eksperimentalne i kontrolne grupe u provedenom prvom glavnom istraživanju prije isključivanja neodgovarajućih čestica	234
Tablica 104. Pregled isključenih čestica iz skala i daljnje obrade u provedenom prvom glavnom istraživanju	236
Tablica 105. Usporedni prikaz analize anketnog upitnika prije i nakon isključivanja neodgovarajućih čestica iz skala	237
Tablica 106. Analiza rezultata eksperimentalne i kontrolne grupe u provedenom prvom glavnom istraživanju nakon korekcije svih skala	238
Tablica 107. Analiza čestica treće cjeline anketnog upitnika (za čestice od 1 do 19) koja se odnosi na procjenu mišljenja ispitanika u provedenom prvom glavnom istraživanju ...	239

Tablica 108. Analiza čestica treće cjeline anketnog upitnika (za čestice od 20 do 41) koja se odnosi na utjecaj motivacijskih elemenata iz računalnih igara na učenje ispitanika u provedenom prvom glavnom istraživanju	240
Tablica 109. Testiranje statističke značajnosti razlike metodom t-testa između prosječnih rezultata odgovora na sve čestice treće cjeline anketnog upitnika	241
Tablica 110. Testiranje statističke značajnosti razlike metodom t-testa između prosječnih rezultata odgovora druge cjeline nakon korekcije anketnog upitnika	242
Tablica 111. Izvještaj o aktivnosti eksperimentalne i kontrolne grupe polaznika	243
Tablica 112. Usporedni prikaz korištenja nastavnih i bonus materijala unutar kolegija "PRO"	245
Tablica 113. Usporedni prikaz testiranja statističke značajnosti razlike metodom t-testa između rezultata predtesta i rezultata posttesta kod svih ispitanika eksperimentalne (G_E) i kontrolne (G_K) grupe	247
Tablica 114. Skraćeni prikaz analize odgovora iz provedenog posttesta u prvom glavnom istraživanju	248
Tablica 115. Prikaz rezultata za 50% najboljih i 50% najlošijih ispitanika eksperimentalne i kontrolne grupe	250
Tablica 116. Prikaz rezultata usporedbe muških i usporedbe ženskih ispitanika eksperimentalne i kontrolne grupe	251
Tablica 117. Usporedni prikaz eksperimentalne i kontrolne grupe nakon predtesta za provjeru znanja	254
Tablica 118. Rezultati predtesta za eksperimentalnu (G_1) grupu ispitanika	255
Tablica 119. Rezultati predtesta za kontrolnu (G_2) grupu ispitanika	255
Tablica 120. Testiranje statističke značajnosti razlike metodom t-testa između rezultata predtesta svih ispitanika eksperimentalne (G_E) i kontrolne (G_K) grupe	255
Tablica 121. Usporedni prikaz eksperimentalne i kontrolne grupe nakon posttesta za provjeru znanja	256
Tablica 122. Rezultati posttesta za eksperimentalnu (G_1) grupu ispitanika	257
Tablica 123. Rezultati posttesta za kontrolnu (G_2) grupu ispitanika	257
Tablica 124. Testiranje statističke značajnosti razlike metodom t-testa između rezultata posttesta svih ispitanika eksperimentalne (G_E) i kontrolne (G_K) grupe	257
Tablica 125. Analiza otvorenog tipa pitanja posttest provjere znanja u drugom glavnom istraživanju	258
Tablica 126. Usporedni prikaz analize odgovora iz provedene posttest provjere znanja u drugom glavnom istraživanju	260
Tablica 127. Analiza težine pitanja u provedenom predtestu drugog glavnog istraživanja	261

Tablica 128. Analiza težine pitanja u provedenom posttestu drugog glavnog istraživanja	262
Tablica 129. Analiza odgovora svih ispitanika u provedenom drugom glavnom istraživanju prema učestalosti korištenja računala i Internet tehnologije	264
Tablica 130. Analiza odgovora svih ispitanika u provedenom drugom glavnom istraživanju s obzirom na dužinu korištenja Internet tehnologije	266
Tablica 131. Analiza odgovora svih ispitanika u provedenom drugom glavnom istraživanju s obzirom na korištenje tehnologije e-učenja	268
Tablica 132. Analiza skala druge cjeline anketnog upitnika u provedenom drugom glavnom istraživanju prije isključivanja neodgovarajućih čestica iz skala	269
Tablica 133. Analiza čestica treće cjeline anketnog upitnika (za čestice od 1 do 19) koja se odnosi na procjenu mišljenja ispitanika u provedenom drugom glavnom istraživanju	270
Tablica 134. Analiza čestica treće cjeline anketnog upitnika (za čestice od 20 do 41) koja se odnosi na utjecaj motivacijskih elemenata iz računalnih igara na učenje ispitanika u provedenom drugom glavnom istraživanju	271
Tablica 135. Analiza rezultata eksperimentalne i kontrolne grupe u provedenom drugom glavnom istraživanju prije isključivanja neodgovarajućih čestica	272
Tablica 136. Pregled isključenih čestica iz skala i daljnje obrade u provedenom drugom glavnom istraživanju	274
Tablica 137. Usporedni prikaz analize anketnog upitnika prije i nakon isključivanja neodgovarajućih čestica iz skala	275
Tablica 138. Analiza rezultata eksperimentalne i kontrolne grupe u provedenom drugom glavnom istraživanju nakon korekcije svih skala	276
Tablica 139. Analiza čestica treće cjeline anketnog upitnika (za čestice od 1 do 19) koja se odnosi na procjenu mišljenja ispitanika u provedenom drugom glavnom istraživanju	277
Tablica 140. Analiza čestica treće cjeline anketnog upitnika (za čestice od 20 do 41) koja se odnosi na utjecaj motivacijskih elemenata iz računalnih igara na učenje ispitanika u provedenom drugom glavnom istraživanju	278
Tablica 141. Testiranje statističke značajnosti razlike metodom t-testa između prosječnih rezultata odgovora na sve čestice treće cjeline anketnog upitnika (čestice od 1 do 41)	279
Tablica 142. Testiranje statističke značajnosti razlike metodom t-testa između prosječnih rezultata odgovora druge cjeline nakon korekcije anketnog upitnika	280
Tablica 143. Izvještaj o aktivnosti eksperimentalne i kontrolne grupe polaznika	281
Tablica 144. Usporedni prikaz korištenja nastavnih i bonus materijala u kolegiju "RPK"	283

Tablica 145. Usporedni prikaz testiranja statističke značajnosti razlike metodom t-testa između rezultata predtesta i rezultata posttesta kod svih ispitanika eksperimentalne (G _E) i kontrolne (G _K) grupe	285
Tablica 146. Skraćeni prikaz analize odgovora iz provedenog posttesta u drugom glavnom istraživanju	286
Tablica 147. Usporedni prikaz analize odgovora iz provedenog posttesta svih triju istraživanja (za ispitanike koji su ostvarili minimalno 50% mogućih bodova u predtestu)	304
Tablica 148. Skraćeni prikaz analize odgovora iz provedenog posttesta svih triju istraživanja (za ispitanike koji su ostvarili minimalno 50% mogućih bodova u predtestu)	305

POPIS SLIKA IZ PRILOGA

Slika A. Primjer zamolbe za odobrenje aktivnosti drugog glavnog istraživanja	326
Slika B. Primjer uputa za kontrolnu grupu ispitanika za prvo glavno istraživanje	327
Slika C. Primjer uputa za eksperimentalnu grupu ispitanika za prvo glavno istraživanje	328
Slika D. Primjer uputa za eksperimentalnu grupu ispitanika za prvo glavno istraživanje	329
Slika E. Primjer predtesta kreiranog za predistraživanje	330
Slika F. Primjer posttesta kreiranog za predistraživanje	331
Slika G. Primjer predtesta kreiranog za prvo glavno istraživanje	332
Slika H. Primjer posttesta kreiranog za prvo glavno istraživanje	333
Slika I. Primjer predtesta kreiranog za drugo glavno istraživanje	334
Slika J. Primjer posttesta kreiranog za drugo glavno istraživanje	335
Slika K. Primjer anketnog upitnika kreiranog za predistraživanje - 1. dio	336
Slika L. Primjer anketnog upitnika kreiranog za predistraživanje - 2. dio	337
Slika M. Primjer anketnog upitnika kreiranog za predistraživanje - 3. dio	338
Slika N. Primjer anketnog upitnika kreiranog za predistraživanje - 4. dio	339
Slika O. Primjer anketnog upitnika kreiranog za predistraživanje - 5. dio	340
Slika P. Primjer anketnog upitnika kreiranog za predistraživanje - 6. dio	341
Slika Q. Primjer anketnog upitnika kreiranog za predistraživanje - 7. dio	342
Slika R. Primjer anketnog upitnika kreiranog za predistraživanje - 8. dio	343
Slika S. Primjer anketnog upitnika kreiranog za oba glavna istraživanja - 1. dio	344
Slika T. Primjer anketnog upitnika kreiranog za oba glavna istraživanja - 2. dio	345
Slika U. Primjer anketnog upitnika kreiranog za oba glavna istraživanja - 3. dio	346
Slika V. Primjer anketnog upitnika kreiranog za oba glavna istraživanja - 4. dio	347
Slika W. Primjer anketnog upitnika kreiranog za oba glavna istraživanja - 5. dio	348
Slika X. Primjer anketnog upitnika kreiranog za oba glavna istraživanja - 6. dio	349

POPIS TABLICA IZ PRILOGA

Tablica P.1. Faktorska analiza anketnog upitnika za podatke iz prvog glavnog istraživanja	352
Tablica P.2. Rezultati predtesta za prvu eksperimentalnu (G1) grupu ispitanika	353
Tablica P.3. Rezultati predtesta za drugu eksperimentalnu (G4) grupu ispitanika	353
Tablica P.4. Rezultati predtesta za prvu kontrolnu (G2) grupu ispitanika	353
Tablica P.5. Rezultati predtesta za drugu kontrolnu (G3) grupu ispitanika	354
Tablica P.6. Rezultati posttesta za prvu eksperimentalnu (G1) grupu ispitanika	354
Tablica P.7. Rezultati posttesta za drugu eksperimentalnu (G4) grupu ispitanika	354
Tablica P.8. Rezultati posttesta za prvu kontrolnu (G2) grupu ispitanika	355
Tablica P.9. Rezultati posttesta za drugu kontrolnu (G3) grupu ispitanika	355
Tablica P.10. Skala: Zadovoljstvo korištenja e-tečaja	355
Tablica P.11. Skala: Pregled nad tečajem / navigacija	356
Tablica P.12. Skala: Povratne informacije u e-tečaju	356
Tablica P.13. Skala: Zaokupljenost / uživljavanje	357
Tablica P.14. Skala: Priprema / uputa za rad s e-tečajem	357
Tablica P.15. Skala: Primjerena težina e-tečaja	358
Tablica P.16. Skala: Motivacijski poticaji	358
Tablica P.17. Skala: Agregacija elemenata za motivacijske poticaje	358
Tablica P.18. Skala: Interakcija unutar e-tečaja	359
Tablica P.19. Skala: Postignuće učenja	359
Tablica P.20. Skala: Individualni proces učenja	359
Tablica P.21. Skala: Doživljaj e-tečaja	360
Tablica P.22. Skala: Evaluacija e-tečaja (za čestice od 1 do 15)	360
Tablica P.23. Skala: Evaluacija e-tečaja (za čestice od 16 do 30)	361
Tablica P.24. Analiza skala druge cjeline anketnog upitnika u provedenom predistraživanju nakon isključivanja neodgovarajućih čestica iz skala	362
Tablica P.25. Rezultati predtesta za prvu eksperimentalnu (G2) grupu ispitanika	363
Tablica P.26. Rezultati predtesta za drugu eksperimentalnu (G3) grupu ispitanika	363
Tablica P.27. Rezultati predtesta za treću eksperimentalnu (G5) grupu ispitanika	363
Tablica P.28. Rezultati predtesta za četvrtu eksperimentalnu (G7) grupu ispitanika	364
Tablica P.29. Rezultati predtesta za petu eksperimentalnu (G11) grupu ispitanika	364
Tablica P.30. Rezultati predtesta za šestu eksperimentalnu (G12) grupu ispitanika	364

Tablica P.31. Rezultati predtesta za sedmu eksperimentalnu (G14) grupu ispitanika	364
Tablica P.32. Rezultati predtesta za prvu kontrolnu (G1) grupu ispitanika	365
Tablica P.33. Rezultati predtesta za drugu kontrolnu (G4) grupu ispitanika	365
Tablica P.34. Rezultati predtesta za treću kontrolnu (G6) grupu ispitanika	365
Tablica P.35. Rezultati predtesta za četvrtu kontrolnu (G8) grupu ispitanika	365
Tablica P.36. Rezultati predtesta za petu kontrolnu (G9) grupu ispitanika	366
Tablica P.37. Rezultati predtesta za šestu kontrolnu (G10) grupu ispitanika	366
Tablica P.38. Rezultati predtesta za sedmu kontrolnu (G13) grupu ispitanika	366
Tablica P.39. Rezultati posttesta za prvu eksperimentalnu (G2) grupu ispitanika	367
Tablica P.40. Rezultati posttesta za drugu eksperimentalnu (G3) grupu ispitanika	367
Tablica P.41. Rezultati posttesta za treću eksperimentalnu (G5) grupu ispitanika	367
Tablica P.42. Rezultati posttesta za četvrtu eksperimentalnu (G7) grupu ispitanika	368
Tablica P.43. Rezultati posttesta za petu eksperimentalnu (G11) grupu ispitanika	368
Tablica P.44. Rezultati posttesta za šestu eksperimentalnu (G12) grupu ispitanika	368
Tablica P.45. Rezultati posttesta za sedmu eksperimentalnu (G14) grupu ispitanika	368
Tablica P.46. Rezultati posttesta za prvu kontrolnu (G1) grupu ispitanika	369
Tablica P.47. Rezultati posttesta za drugu kontrolnu (G4) grupu ispitanika	369
Tablica P.48. Rezultati posttesta za treću kontrolnu (G6) grupu ispitanika	369
Tablica P.49. Rezultati posttesta za četvrtu kontrolnu (G8) grupu ispitanika	369
Tablica P.50. Rezultati posttesta za petu kontrolnu (G9) grupu ispitanika	370
Tablica P.51. Rezultati posttesta za šestu kontrolnu (G10) grupu ispitanika	370
Tablica P.52. Rezultati posttesta za sedmu kontrolnu (G13) grupu ispitanika	370
Tablica P.53. Skala: Zadovoljstvo korištenja e-tečaja	371
Tablica P.54. Skala: Pregled nad tečajem / navigacija	371
Tablica P.55. Skala: Povratne informacije u e-tečaju	372
Tablica P.56. Skala: Zaokupljenost / uživljanje	372
Tablica P.57. Skala: Priprema / uputa za rad s e-tečajem	372
Tablica P.58. Skala: Primjerena težina e-tečaja	373
Tablica P.59. Skala: Motivacijski poticaji	373
Tablica P.60. Skala: Agregacija elemenata za motivacijske poticaje	373
Tablica P.61. Skala: Interakcija unutar e-tečaja	374
Tablica P.62. Skala: Postignuće učenja	374
Tablica P.63. Skala: Individualni proces učenja	374

Tablica P.64. Skala: Doživljaj e-tečaja	375
Tablica P.65. Skala: Evaluacija e-tečaja (za čestice od 1 do 15)	375
Tablica P.66. Skala: Evaluacija e-tečaja (za čestice od 17 do 28)	376
Tablica P.67. Analiza skala druge cjeline anketnog upitnika u provedenom prvom glavnom istraživanju nakon isključivanja neodgovarajućih čestica iz skala	377
Tablica P.68. Skala: Zadovoljstvo korištenja e-tečaja	378
Tablica P.69. Skala: Pregled nad tečajem / navigacija	378
Tablica P.70. Skala: Povratne informacije u e-tečaju	379
Tablica P.71. Skala: Zaokupljenost / uživljanje	379
Tablica P.72. Skala: Priprema / uputa za rad s e-tečajem	379
Tablica P.73. Skala: Primjerena težina e-tečaja	380
Tablica P.74. Skala: Motivacijski poticaji	380
Tablica P.75. Skala: Agregacija elemenata za motivacijske poticaje	380
Tablica P.76. Skala: Interakcija unutar e-tečaja	381
Tablica P.77. Skala: Postignuće učenja	381
Tablica P.78. Skala: Individualni proces učenja	381
Tablica P.79. Skala: Doživljaj e-tečaja	382
Tablica P.80. Skala: Evaluacija e-tečaja (za čestice od 1 do 15)	382
Tablica P.81. Skala: Evaluacija e-tečaja (za čestice od 17 do 28)	383

POPIS KRATICA

3DM	kolegij pod nazivom "3D modeliranje"
ARG	eng. <i>Augmented Reality Game</i>
DMGL	eng. <i>Dynamical model for gamification of learning</i>
GBL	eng. <i>Game Based Learning</i>
GNU	eng. <i>GNU's Not Unix</i>
eRIOOS	elementi računalnih igara u obrazovnom online sustavu
ICT	eng. <i>Information and communications technology</i>
LAN	eng. <i>Local Area Network</i>
LMS	eng. <i>Learning Management System</i>
LTI	eng. <i>Learning Tools Interoperability</i>
MDA	eng. <i>Mechanics, Dynamics and Aesthetics</i>
MMO	eng. <i>Massively Multiplayer Online</i>
Moodle	eng. <i>Modular Object-Oriented Dynamic Learning Environment</i>
MUD	eng. <i>Multi User Dungeon</i>
PBL	eng. <i>Point, Badge, Leaderboard</i>
PRO	kolegij pod nazivom "Programiranje 2"
RAMP	eng. <i>Relatedness, Autonomy, Mastery, Purpose</i>
RPK	kolegij pod nazivom "Računalom posredovana komunikacija"
SCORM	eng. <i>Sharable Content Object Reference Model</i>
SN	eng. <i>Social Networks</i>
URL	eng. <i>Uniform Resource Locator</i>
WWW	eng. <i>World Wide Web</i>

1. UVOD

Unutar ovog poglavlja opisuje se i definira istraživački problem koji je tema ove disertacije. Navode se ciljevi i hipoteze istraživanja, ističe se slika tijekom istraživanja, kao i opis teorijskog i empirijskog dijela istraživanja.

1.1. Struktura doktorske disertacije

Tema disertacije izložena je u šest poglavlja, osim prvog uvodnog i osmog zaključnog poglavlja.

- U poglavlju pod nazivom "**2. Pedagoški i tehnološki aspekti e-učenja**" navode se razmatranja i definicije pojma e-učenje, koje se analizira i razdvaja na osnovne elemente. Slijedi klasifikacija te se navode **vrste e-učenja** koje služe kao uvod u korištenje e-učenja u visokoškolskom obrazovanju. Slijedi opis budućeg razvoja e-učenja i **upoznavanje Moodle platforme** pomoću koje je provedeno istraživanje opisano unutar ove disertacije. Poglavlje se zaključuje međudnosom pedagoških teorija i e-učenjem te teorijama i vrstama procjene znanja.
- Unutar poglavlja pod nazivom "**3. Gemifikacija e-učenja**" objašnjava se pojam i daje se teoretski opis pronađen u literaturi. Navode se elementi i struktura gemifikacijskog pristupa, među kojima su najznačajnija **mehanika, dinamika i estetika** (komponente) **računalnih igara**. Objasnjeni su **tipovi igrača** i princip **uvođenja motivirajućih elemenata računalnih igara** u obrazovni sustav. Poglavlje se dopunjuje principima učenja pomoću elemenata računalnih igara te se navode primjeri elemenata računalnih igara koji su pogodni za korištenje u obrazovnom sustavu.
- Unutar poglavlja pod nazivom "**4. Dizajn e-tečaja**" predstavlja se postojeće stanje i izgled prosječnog Moodle tečaja koji se koristi unutar obrazovnog sustava. Navode se nužni preduvjeti i daje se **popis** pogodnih **elemenata računalnih igara** koji se mogu uključiti unutar Moodle platforme. Opisuju se elementi računalnih igara i prikazuje se proces izrade i implementacije idejnog rješenja za *eksperimentalni* e-tečaj.
- U poglavlju pod nazivom "**5. Opis i obilježja istraživanja**" navode se ciljevi i hipoteze, kao i instrumenti koji su korišteni unutar istraživačkog rada ove disertacije. Za potrebe istraživanja koristi se *pretest* koji je usmjeren na utvrđivanje predznanja. Koristi se radi upoznavanja ispitanika i ispitivanja početnih statistički značajnih razlika.

Opisuje se i *posttest*, koji je ujedno i test stečenog znanja, a koristi se radi provjere znanja nakon korištenja *eksperimentalnog* sustava. *Posttest* je važan za utvrđivanje statistički značajnih razlika između grupa ispitanika. Treći instrument koji se koristio u znanstvenoistraživačkom radu jest *anketni upitnik*, koji je u potpunosti kreiran na temelju istraživanja literature i stručne pomoći mentora.

Anketni upitnik podijeljen je u tri cjeline, gdje je **prva cjelina** namijenjena osobnim podacima te broji ukupno 19 čestica unutar jedne mjerne skale. **Druga cjelina** ima ukupno 150 čestica, koje su podijeljene u 13 mjernih skala. **Treća cjelina** *anketnog upitnika* evidentirana je pod nazivom *Evaluacija elemenata računalnih igara*, a sastoji se od 41 čestice. Prvih 19 pitanja odnosi se na općenitu procjenu **mišljenja** ispitanika, dok se drugi dio od 22 pitanja odnosi na **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika. Poglavlje 5. završava upoznavanjem svih triju grupa ispitanika te opisima pilot-tečaja i *eksperimentalnih* tečaja.

- Unutar poglavlja "**6. Rezultati istraživanja**" nalazi se po jedna cjelina za svako provedeno istraživanje. Prvo istraživanje je *Predistraživanje* koje se provodilo unutar okvira e-tečaja pod nazivom "Osvjetljenje i renderiranje" na kolegiju "3D modeliranje" na Sveučilištu Sjever. Drugo istraživanje navodi se pod nazivom *Prvo glavno istraživanje*, a provodilo se tijekom e-tečaj "Hrpa i stog" na kolegiju "Programiranje 2" na Fakultetu organizacije i informatike. Treće istraživanje navodi se pod nazivom *Drugo glavno istraživanje*, a provodilo se unutar e-tečaja "Multimedija" na kolegiju "Računalom posredovana komunikacija" Fakulteta organizacije i informatike.
- Unutar poglavlja "**7. Diskusija**" opisuju se uvjeti i rezultati empirijskog istraživanja ove disertacije. Navode se rezultati svih triju istraživanja te se daje osvrt na hipoteze H1 i H2, isto kao i na podhipoteze H1.1, H2.1, H2.2, H2.3, H2.4, H2.5. Poglavlje se zaključuje uvidom u nekoliko doktorskih disertacija koje imaju gemifikaciju za predmet proučavanja.
- Unutar poglavlja "**8. Zaključak**" daje se kratak pregled istraživanja iz područja primjene gemifikacije u e-učenju, kao i uvid u metodologiju istraživanja. Pobrojani su ciljevi i hipoteze te struktura teorijskog i empirijskog pristupa istraživanju. Opisani su postupci prema kojima su testirane tvrdnje hipoteza H1 i H2, kao i podhipoteza H1.1, H2.1, H2.2, H2.3, H2.4, H2.5. kao i doprinosi istraživanja. Slijedi osvrt na ograničavajuće elemente te njihova analiza. Poglavlje se zaključuje najavom mogućih smjerova za buduća istraživanja.

1.2. Definiranje problema istraživanja

Nastavnici u obrazovanju koriste igre dugi niz godina u vidu poučavanja pomoću specijaliziranih **obrazovnih ili komercijalnih računalnih igara**. Glavni je razlog tome što su igre **zabavne** i na dinamičan način mogu pristupiti određenoj temi ili objektu poučavanja. Digitalne igre postale su ključna i svakodnevna komponenta u čovjekovoj socijalizaciji, gdje se shvaćanje igara proširuje i nadilazi svrha čiste zabavne forme. Deterding i suradnici (2011.) te Tomić (2012.) govore kako tehnologija i same računalne igre uvelike mijenjaju tradicionalne granice obrazovanja, što je vidljivo kroz industrijski pristup i sve veći broj istraživanja ove teme. Njihova istraživanja potvrđuju **pozitivan stav** ispitanika koji koriste dinamične interaktivne sustave, gdje je naglasak na **učenju i utjecaju na ponašanje** pomoću računalnih simulacija (ekonomskih, političkih, vojnih, građevinskih i dr.) u kojima korisnik igra određeni **scenarij** i prati kako se njegove **odluke odražavaju na ciljeve i rezultate** koji su postavljeni **kao ishodi učenja**. U ovu svrhu mogu se koristiti komercijalne igre ili usko specijalizirane, posebno razvijene obrazovne igre za određeno područje. Oba izbora doprinose obrazovnoj izvrsnosti.

Uz obrazovne metode koje se temelje na igranju računalnih igara, **sredinom 2010.** počinju se razmatrati sustavi koji nisu računalne igre, ali imaju sve elemente koji su prepoznati u računalnim igrama (Deterding, 2011.; Aparicio, 2012.). Pojam koji se navodi i istražuje je **gemifikacija** i predstavlja korištenje elemenata (**mehanike, dinamike i estetika**) računalnih igara u području koji nije računalna igra (Deterding, 2011.; Aparicio, 2012.). U istraživanju literature vidljivo je kako istraživači, međunarodne kompanije i ugledne obrazovne institucije pridaju sve veću pozornost i važnost elementima računalnih igara (Bruke, 2013.). Navedeni elementi analiziraju se i implementiraju u sustave koji predstavljaju temelj komunikacijskog, obrazovnog, organizacijskog i poslovnog funkcioniranja društva (van der Meulen, 2013.).

Populacija o kojoj se često govori jesu pojedinci rođeni između 1995. i 2009. godine, koji se još nazivaju i "**Generacijom Z**" (**Ramar i Owens, 2016.**). Ovdje se govori o pojedincima koji jesu ili tek postaju dio visokoškolskog sustava te dijelom poslovnog djelovanja. Posebnost je takvih pojedinaca u tome što su tijekom odrastanja konstantno bili i još uvijek jesu, izloženi **mobilnim i računalnim tehnologijama**, kao i utjecaju **računalnih igara**.

Pojam zabave kod njih je baziran na **dinamičnijim sustavima** koji se uvelike oslanjaju na tehnološke mogućnosti okoline i kao takav očekuje se i traži u budućim situacijama u životu. Dolaskom do visokoškolskog obrazovanja student se upoznaje s **LMS** sustavima (eng. *learning*

management system), od kojih je najkorišteniji sustav otvorenog koda pod nazivom **Moodle**, koji omogućuje prilagodbu korisničkog sučelja i korištenje elemenata računalnih igara ovisno o studentovim karakteristikama i zahtjevima samog kolegija (Souza-Concilio i Pacheco, 2013.). LMS sustavi pokušavaju se približiti studentima kroz **komunikacijske** i **kolaboracijske** alate, gdje se teži trenutnoj **povratnoj informaciji o uspješnosti**, kao i vizualnoj prezentaciji informacija važnih studentu.

Jaz koji se događa povezan je s činjenicom da student iz vrlo dinamičkog tehnološkog okruženja dolazi u visokoškolsku instituciju koja često prenosi znanje određenog područja na jedan od triju načina: 1) predavanje nastavnika **frontalnim metodama rada**, 2) auditorne ili laboratorijske vježbe, gdje se često slijede **korak po korak** upute asistenata, 3) kroz LMS sustav **literature, natuknica i pitanja** o određenoj temi.

Evidentna je potreba i tehnološka mogućnost za podizanjem **online obrazovanja** na višu razinu, koji se bazira na **pedagoškim i psihološkim promjenama** koje utječu na studentovu percepciju nastavnog sadržaja i motivaciju za **aktivno sudjelovanje, istraživanje i suradnju** (Deterding, 2012.; Adeel, 2014.). Evidentirani pomak mogao bi se analizirati s obzirom na tradicionalno učenje, gdje je prva prilagodba bila statičan *online* sustav obrazovanja koji se proširio u domenu 3D virtualnih svjetova, a tu je **Second Life** najrašireniji i najkorišteniji proizvod. Second Life je ideja koja pokazuje mogućnosti povezivanja **obrazovanja i 3D virtualnog prostora** koja će se uz niz preinaka uvelike koristiti u budućnosti.

Gemifikaciju kao pojam i suvremeni trend prepoznao je Google i mnoge nezavisne istraživačke kompanije, među kojima se izdvajaju **Gartnerova i M2 istraživanja** (Lepper, 1992.; van der Meulen, 2013.; Webb, 2013.). U **Gartnerovom** izvješću 2013. gemifikacija je pozicionirana kao **tehnološka inovacija** o kojoj se najviše govori i čiji se razvoj prati s iznimnom važnošću (LeHong, 2012.; Webb, 2013.; Bruke, 2013.).

Potvrda navedenog je "**GSummit 2014**", konferencija o gemifikaciji koja se održala u San Franciscu i gdje su bili govornici, investitori i prisutni članovi najvećih svjetskih kompanija koji traže gemificirano rješenje za svoje proizvode i sustave ili su zainteresirani za **investiranje u razvoj i poslovne gemificirane projekte (Gamification Summit, 2014.)**. Konferencija pod nazivom **Gamification World Conference 2016** održava se već dvije godine zaredom u Madridu u Španjolskoj, uz prisutnost najpoznatijih istraživača gemifikacije i gemifikacijskih tehnologija u svijetu, kao što su R. Bartle, M. Herger, A. Marczewski, K. Werbach i G. Zichermann (GWC, 2016.).

Fokus dosadašnjih istraživanja većinom je bio na pokazivanju kako navedeni pristup daje **pozitivne** rezultate u **poslovanju, marketingu i obrazovanju** (Radoff, 2011.; McGonigal, 2011.; Rauch, 2012.; Kim, 2013.). Također se pokazuje kako elementi računalnih igara mogu pozitivno utjecati na **pedagoške i psihološke osobine** studenata (Smole, 2007.; Werbach, 2012.). Uočeno je i to da **ne postoji standardiziran skup** i nije **jasno definirano** koji su to elementi računalnih igara o kojima bi trebalo posebno voditi računa i **kako ih postaviti** u odnosu na postojeće *online* sustave obrazovanja.

Glavni problem koji autor ovog rada uočava jest nedostatak **teorijskog i empirijskog ispitivanja i povezivanja LMS sustava i elemenata računalnih igara** koje bi rezultiralo skupom pravila, instrukcija i definicija kako pravilno postaviti sustav jer je poznato, a Gartner u svojim istraživanjima jasno navodi, da će većina sustava koja su krenula s implementacijom elemenata računalnih igara **biti neuspješna**, primarno zbog **lošeg dizajna i povezivanja elemenata računalnih igara s postojećim online rješenjima**. Uz navedeno postoji niz istraživačkih pitanja na koja nije pronađen odgovor prilikom analiziranja literature, primjerice *kada sustav postaje, a kada prestaje biti gemificiran ili postoji li skup od nekoliko najboljih gemificiranih elemenata, koji postižu najbolje rezultate vezano uz motivaciju korisnika*.

Iz navedenog je vidljivo kako su **potrebna daljnja istraživanja** vezana uz uvođenje elemenata računalnih igara u područje visokoškolskog obrazovanja, s naglaskom na *online* poučavanje sadržaja informatičkih predmeta. Razlog tome vezan je uz gemifikaciju kao pojam koji općenito i u *online* obrazovanju predstavlja novo područje koje je **nedovoljno opisano** i istraženo. Sugeriraju se teorijska i empirijska istraživanja, kao i **analiziranje i standardizacija elemenata računalnih igara** koji bi mogli doći u obzir prilikom njihove implementacije u *online* Moodle sustav za poučavanje.

1.3. Ciljevi i hipoteze istraživanja

U ovoj disertaciji pod nazivom "**Uvođenje elemenata računalne igre u *online* poučavanje sadržaja informatičkih nastavnih predmeta**" prikazana je primjena mješovite metodologije istraživanja. U teoretskom dijelu istraživanja korištene su kvalitativne opće znanstvene metode poput metode opservacije, deskripcije, komparacije te metoda sinteze i analize sadržaja. Navedene metode koristile su se za ostvarenje prvih triju ciljeva disertacije.

- **Prvi cilj** istraživanja jest ispitati potrebu za uvođenjem elemenata računalnih igara u e-učenje na visokim učilištima.
- **Drugi je cilj** istražiti motivirajuće elemente računalnih igara koji bi se mogli koristiti u području *online* poučavanja sadržaja informatičkih predmeta.
- **Treći cilj** predstavlja razvoj konceptualnog modela gemifikacije za poučavanje u *online* okruženju, koji je temelj za izradu *gemificiranog* Moodle e-tečaja u području poučavanja sadržaja informatičkih predmeta.

Treći cilj govori o kreiranju **konceptualnog modela eRIOOS** (elementi računalnih igara u *online* obrazovnom sustavu), koji je kreiran za potrebe istraživačkog rada. Konceptualan model **teorijski** je i **empirijski utemeljen** jer se temelji na istraživanjima drugih znanstvenika te uvažavanju njihovih zaključaka glede korištenja elemenata računalnih igara unutar odgojno-obrazovnog sustava. Konceptualan model eRIOOS predstavlja temelj za *gemificirani* sustav, koji je prvi put korišten u *predistraživanju* u okviru Sveučilišta Sjever (N=55). Kasnije se koristi i u *prvom* i *drugom glavnom* istraživanju, koja su provedena na Fakultetu organizacije i informatike (N=254). Rezultati ispitanika, koji su temeljeni na prosječnim bodovima *predtesta* i *posttesta*, koristili su se za ostvarenje četvrtog cilja disertacije.

- **Četvrti cilj** odnosi se na provjeru je li primjena **motivirajućih elemenata računalnih igara** omogućila ostvarenje **viših razina ishoda učenja** u *eksperimentalnoj* skupini ispitanika. Konceptualni model usmjeren je na unapređenje i primjenu **elemenata računalnih igara** u *online* obrazovnom sustavu (eRIOOS).

Četvrti cilj dopunjen je rezultatima analize koji su dobiveni na temelju prosječnih bodova svih ispitanika tijekom provjere u *predtestu* i *posttestu*. Nakon *prvog glavnog istraživanja* kreiran je posljednji *gemificirani* sustav koji se koristio u *drugom glavnom istraživanju*, u kojemu se još jednom provjerava **ispravnost** konceptualnog **modela eRIOOS** i ostvarenje četvrtog cilja.

S ciljem preciznijeg definiranja smjera istraživanja, postavljena je prva glavna hipoteza H1:

- **H1.** E-tečaj dizajniran uz primjenu elemenata računalnih igara **pozitivno utječe na zainteresiranost** polaznika tog tečaja u odnosu na tečaj istog obrazovnog sadržaja, ali bez prisutnosti elemenata računalnih igara.

Kako bi se potvrdila hipoteza H1, provedeno je **istraživanje literature** s naglaskom na **motivaciju** polaznika i **popratne pozitivne pojave**. Naglasak je bio na suvremenim **informacijsko-komunikacijskim tehnologijama** koje su pronašle primjenu u visokoškolskom obrazovanju. Također, u okviru ove disertacije, empirijskim putem provedeno je mjerenje **zainteresiranosti polaznika gemificiranog** e-tečaja. Mjerenje je provedeno temeljem **anketnog upitnika** koji se sastojao od **150 čestica**, koje su se u svakoj fazi istraživanja korigirale prema unutarnoj konzistentnosti skala. *Anketni upitnik* sastoji se od **triju logičkih dijelova**, gdje prvi dio broji 19 čestica koje se odnose na osobne podatke ispitanika. Drugi dio broji ukupno 150 čestica koje se odnose na povratne informacije o e-tečaju, dok treći sadrži 41 česticu koja se odnosi na utjecaj motivacijskih elemenata iz računalnih igara na učenje ispitanika. Uz analizu rezultata *anketnog upitnika* u obzir se uzima i **izvještaj o aktivnosti** polaznika iz **Moodle sustava**. U odnos se stavljaju obje grupe ispitanika (*eksperimentalna* i *kontrolna*), čijim se rezultatima upotpunjuje zaključak o prihvaćanju tvrdnji hipoteze H1.

Uz hipotezu H1., definirana je i podhipoteza H1.1 koja glasi:

- **H1.1.** Elementi računalnih igara, koji su uključeni u *eksperimentalni* e-tečaj, **pozitivno utječu na veće korištenje nastavnih materijala, u usporedbi s klasičnim e-tečajem koji** sadrži identične nastavne materijale, bez prisutnosti elemenata računalnih igara.

Posebna analiza obuhvatit će samo nastavne i bonus materijale koji su studentima bili na raspolaganju tijekom provedbe istraživanja. Svi ostali elementi računalnih igara, za potrebe potvrđivanja tvrdnje podhipoteze H1.1, bit će izostavljeni iz analize, no pretpostavka jest kako će elementi računalnih igara koji su uključeni u *eksperimentalan* e-tečaj pozitivno utjecati na veće korištenje nastavnih materijala kod *eksperimentalne* skupine ispitanika.

S ciljem dodatnog definiranja smjera istraživanja, postavljena je i druga glavna hipoteza H2:

- **H2.** E-tečaj dizajniran uz primjenu elemenata računalnih igara omogućuje **postizanje boljih rezultata** polaznika u odnosu na tradicionalne pristupe e-učenju, imajući u vidu razinu **stečenog znanja** iz određenog nastavnog sadržaja.

Kako bi se potvrdila hipoteza H2, oblikovano je nekoliko koraka koji se opisuju u nastavku.

- U **prvom koraku** ispitanici se upoznaju s načinom provođenja i svrhom istraživanja. Svaka grupa studenta, s obzirom na termine vježbi, bila je grupirana i u eksperimentu. U ovom trenutku nije poznato je li grupa ispitanika *kontrolna* ili *eksperimentalna*.
- U **drugom koraku** provjerava se jesu li grupe **statistički podjednake**. Na temelju ostvarenih bodova iz *predtesta*, provjerava se statistička značajnost te se donosi zaključak o zadovoljavanju početnih uvjeta istraživanja. Na temelju rezultata *predtesta* zaključuje se kako se grupe statistički značajno ne razlikuju te se ističe mogućnost da u *eksperimentalnom* e-tečaju može doći do statistički značajnih razlika. S obzirom na prosječne bodove, grupe se odvajaju u *eksperimentalnu* i *kontrolnu*. Obje grupe ispitanika, upućene su u njima namijenjene e-tečaje, gdje su izvršavale određene nastavne aktivnosti.
- U **trećem koraku** polaznici oba e-tečaja nastavne su materijale proučavali isključivo kroz e-tečaj. Korištenje sustava trajao je minimalno 14 dana, nakon kojih slijedi testiranje stečenog znanja primjenom *posttest* instrumenta. Testiranje **statističke značajnosti razlike** metodom t-testa provodilo se između istih skupina ispitanika, a izračunavala se **p vrijednost** prema kojoj se može zaključiti, uz mogućnost pogreške od 1% ili 5%, kako između *eksperimentalne* i *kontrolne* grupe **postoji ili ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*. Provjerava se za koliko se rezultat promijenio i donosi se zaključak o prihvaćanju tvrdnje hipoteze H2.

Uz hipotezu H2, definirane su sljedeće podhipoteze **H2.1**, **H2.2**, **H2.3**, **H2.4** i **H2.5** koje se redom navode u nastavku ovog rada:

- **H2.1.** *Eksperimentalna* grupa ispitanika, koja je u *predtest* provjeri znanja ostvarila **minimalno 50%** bodova, postići će **statistički značajnije** rezultate u odnosu na *kontrolnu* grupu ispitanika, koja je u *predtest* provjeri znanja ostvarila **minimalno 50%** bodova, s obzirom na ostvarene bodove u *posttest* provjeri znanja.
- **H2.2.** Bez obzira na spol ispitanika, **50% najbolje** rangiranih studenata *eksperimentalne* grupe ispitanika, *prvog glavnog istraživanja*, ostvarit će statistički značajniji rezultat u odnosu na **50% najbolje** rangiranih studenata *kontrolne* grupe ispitanika.
- **H2.3.** Bez obzira na spol ispitanika, **50% najlošije** rangiranih studenata *eksperimentalne* grupe ispitanika, *prvog glavnog istraživanja*, ostvarit će statistički značajniji rezultat u odnosu na **50% najlošije** rangiranih studenata *kontrolne* grupe ispitanika.

- **H2.4.** Bez obzira na predznanje ispitanika, studenti **muškog spola** *eksperimentalne* grupe u *prvom glavnom istraživanju* ostvarit će statistički značajniji rezultat u odnosu na studente **muškog spola** *kontrolne* grupe ispitanika.
- **H2.5.** Bez obzira na predznanje ispitanika, studenti **ženskog spola** *eksperimentalne* grupe u *prvom glavnom istraživanju* ostvarit će statistički značajniji rezultat u odnosu na studente **ženskog spola** *kontrolne* grupe ispitanika

Važno je naglasiti kako se podhipoteze **H2.2**, **H2.3**, **H2.4** i **H2.5** odnose samo na rezultate *prvog glavnog istraživanja* zbog dovoljno velikog uzorka ispitanika koji su sudjelovali u svim istraživačkim aktivnostima u okviru ovog doktorskog rada.

1.4. Nacrt i metodologija istraživanja

1.4.1. Teorijsko istraživanje

Analizira se područje e-učenja, računalnih igara, gemifikacije i utjecaj na motivaciju u učenju. Koriste se opće znanstvene metode poput opservacije, deskripcije, metode komparacije, metode sinteze i analize sadržaja. Navedenim metodama analiziraju se neki od postojećih Moodle kolegija u području poučavanja sadržaja informatičkih predmeta s ciljem kreiranja konceptualnog modela te ostvarivanja prvog i drugog cilja istraživanja. Konceptualni model je usmjeren na unapređenje i primjenu elemenata računalnih igara u *online* obrazovnom sustavu (eRIOOS).

1.4.2. Empirijsko istraživanje

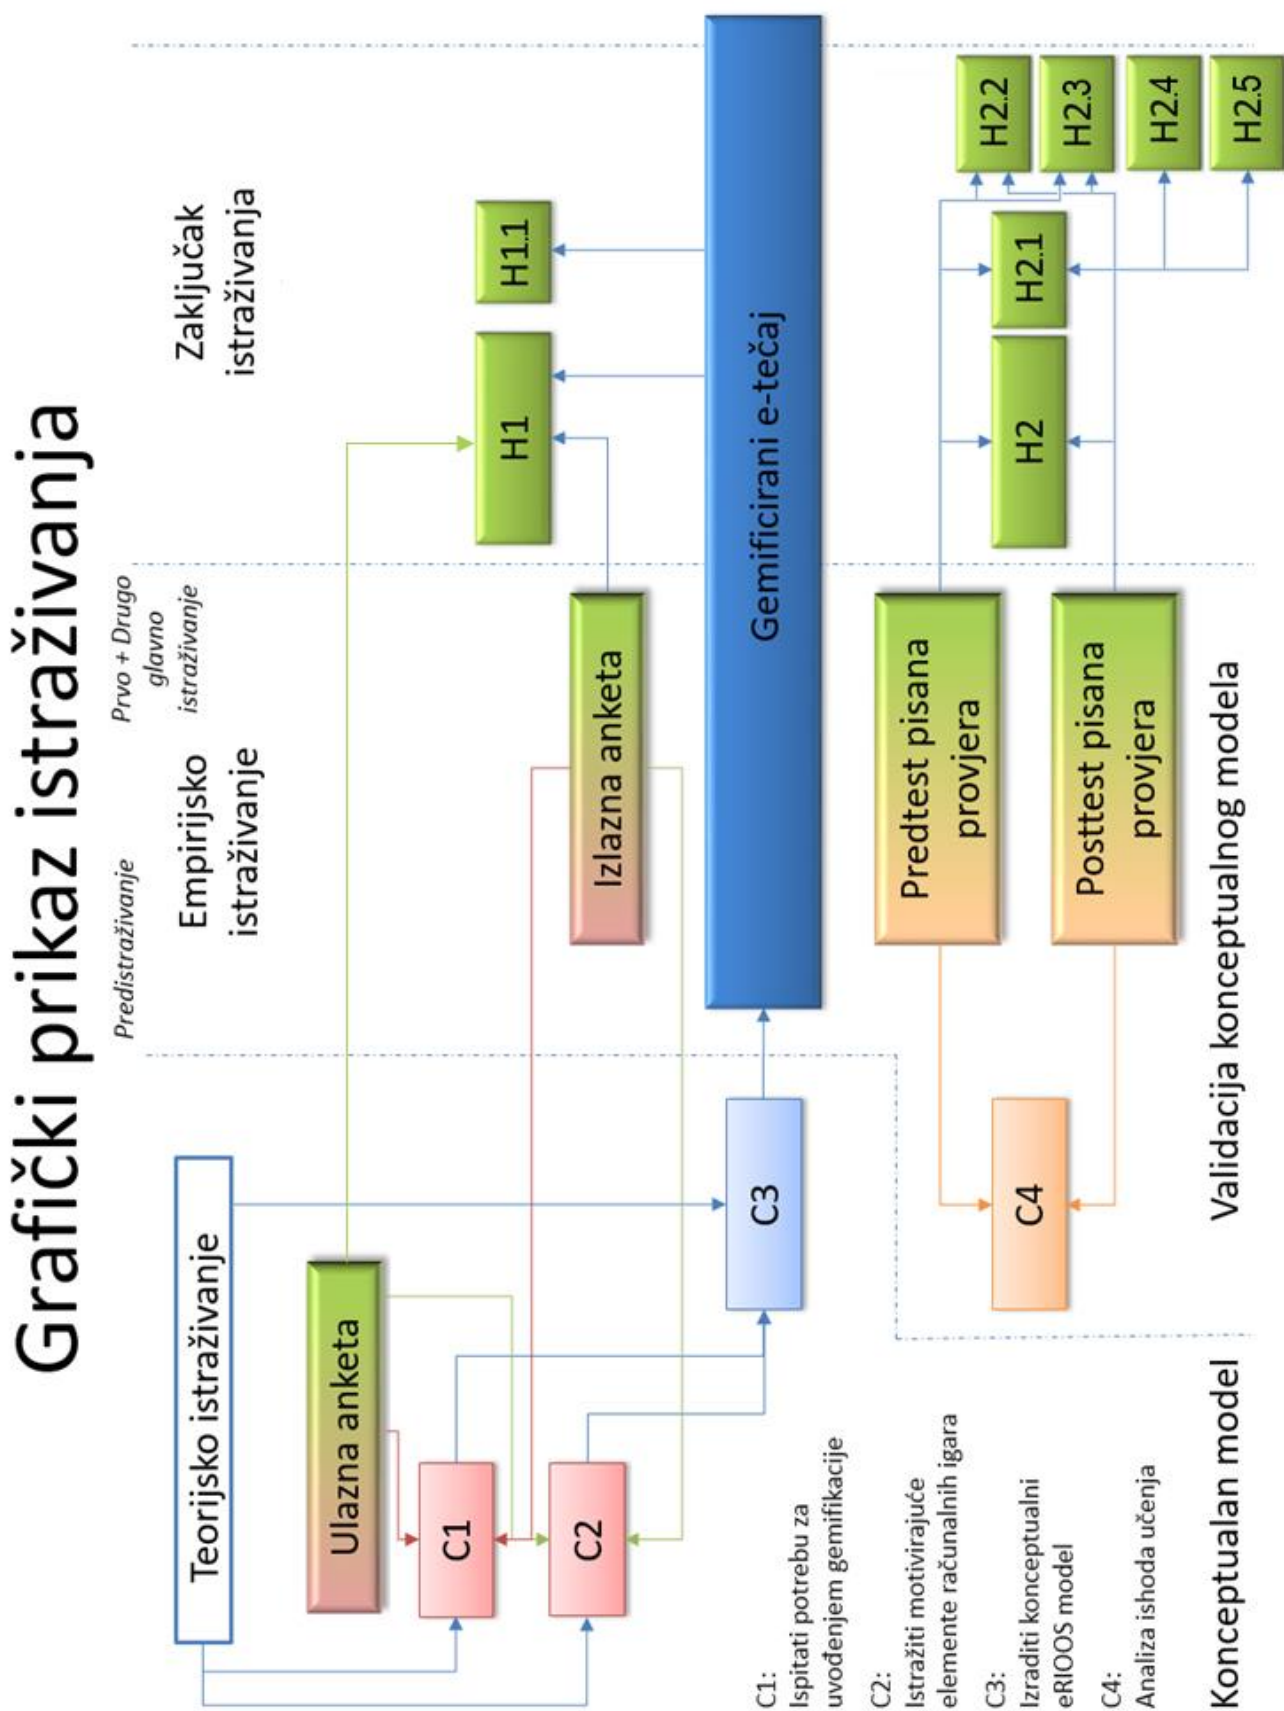
Empirijski dio istraživanja za potrebe ove doktorske disertacije temelji se na provođenju triju zasebnih empirijskih istraživanja. U fazi testiranja provedeno je *predistraživanje* na drugoj godini Sveučilišta Sjever. U ovoj fazi istraživanja primarno je testiran *gemificirani* sustav s ciljem uklanjanja tehničkih i logičkih pogrešaka. U istraživanju je dobrovoljno sudjelovalo 55 ispitanika, koji su ujedno bili i polaznici izbornog kolegija "3D modeliranje". Iz *predistraživanja* kreirani su zaključci koji su ponovno analizirani i uvedeni u *prvo glavno istraživanje* i *drugo glavno istraživanje*. Oba *glavna istraživanja* provedena su na Fakultetu organizacije i informatike u Varaždinu. Ukupan broj ispitanika koji su sudjelovali u glavnom istraživanju iznosi 254. Osnovni preduvjet bio je da su ispitanici polaznici odabranih kolegija ("Programiranje 2" i "Računalom posredovana komunikacija") te da je njihovo sudjelovanje dobrovoljno. Za svako istraživanje zatraženo je i dobiveno dopuštenje nadležnih tijela za uključivanje studenata u eksperiment. Primjer jednog zatraženog dopuštenja nalazi se u prilogima (pogledati prilog 1., slika A).

U nastavku disertacije slijedi pregled faza u skladu s kojima je istraživanje provedeno.

- U **pripreмноj fazi** istraživanja provedena je analiza stručne i znanstvene literature radi ostvarivanja prvog i drugog cilja ove disertacije. Identificiraju se ključni elementi mehanike, dinamike i estetike. Istražuju se **tehnički preduvjeti** za izradu i provođenje istraživanja. Izrađuje se i provodi anketa za analizu prosječnog stanja u Moodle e-tečajevima.
- **Prva faza** provedbe istraživanja počinje analizom i istraživanjem stručne i znanstvene literature radi pronalaska specifičnih smjernica za kreiranje konceptualnog modela usmjerenog na tematiku istraživanja. Kreira se popis *gemificiranih* elemenata za Moodle sustav. Izrađuje se **konceptualan gemificirani model** eRIOOS. Upotpunjuju se zaključci o ciljevima jedan i dva te se ostvaruje treći cilj disertacije.
- U **drugoj fazi** provedbe istraživanja kreiran je **gemificirani Moodle e-tečaj** na temelju konceptualnog modela eRIOOS namijenjen *eksperimentalnoj* grupi ispitanika. Paralelno s navedenim razvijana je i klasična verzija Moodle sustava namijenjena *kontrolnoj* grupi ispitanika. Nastavni materijal prilagođen je za potrebe ovog istraživanja te se međusobno ne razlikuje po svom sadržaju. Druga faza završava analizom stabilnosti i ispravnosti funkcioniranja obaju sustava.
- **Treća faza** provedbe istraživanja vezana je za testiranje **predznanja** polaznika e-tečaja, kao i za raspodjelu polaznika u *eksperimentalne* i *kontrolne* grupe. U tu svrhu kreiran je i proveden *predtest*. Studenti su upućeni u *klasičan* i *gemificirani* e-tečaj koji su koristili minimalno 14 dana. Upoznati su s pravilima istraživanja i korištenjem sustava. U tjednu nakon korištenja e-tečaja, provodi se završna pisana provjera znanja, tj. *posttest* koji se temelji na istom principu kao i u *predtest*. Završna aktivnost unutar treće faze jest provođenje **anketnog upitnika motivacije i zadovoljstva** u kojem se analiziraju ključni elementi e-tečaja i ostali pokazatelji vezani za *gemificirani* Moodle sustav.
- **Četvrta faza** provedbe empirijskog istraživanja temelji se na izračunu statističkih pokazatelja: SD, t-test, Cronbach alpha, mjera centralne tendencije, deskriptivne statistike i ostalih statističkih pokazatelja temeljem kojih se može donijeti pravovaljani zaključak o statističkoj razlici između rezultata ispitanika obje grupa.

Navedene faze prikazane su unutar **grafičkog prikaza istraživanja** na slici 1.

1.5. Grafički prikaz istraživanja



Slika 1. Grafički prikaz istraživanja za potrebe ove doktorske disertacije

Slika istraživanja ove doktorske disertacije opisuje **logički slijed aktivnosti** koje su međusobno vezane te stavlja u **međudnos ciljeve, hipoteze i gemificirani sustav**. Početni element vezan je za teorijsko istraživanje, koji je direktno povezan s ostvarenjem prvih triju ciljeva. Ciljevi su, također, međusobno povezani, tako da prvi i drugi cilj dovode do realizacije trećeg cilja. Treći cilj odnosi se na izradu **konceptualnog modela eRIOOS**, koji je uvjet za kreiranje *eksperimentalnog, gemificiranog* sustava temeljem kojeg se provodi znanstvenoistraživački rad. Konceptualni model usmjeren je na unapređenje i primjenu **elemenata računalnih igara u online obrazovnom sustavu**. Četvrti cilj odnosi se na provjeru je li primjena **motivirajućih elemenata** računalnih igara omogućila ostvarenje **viših razina ishoda učenja** u *eksperimentalnoj* skupini ispitanika.

Gemificirani e-tečaj za svako istraživanje kreiran je **ponovno** jer se e-tečajevi izvode na različitim institucijama (Sveučilište Sjever, Fakultet organizacije i informatike), poslužiteljima, kao i na kolegijima (3d modeliranje, Programiranje 2, Računalom posredovana komunikacija).

Ispitanici koji su sudjelovali u istraživanju dobrovoljno su pristali na istraživačke aktivnosti te su aktivno sudjelovali u validaciji konceptualnog modela. **Validacija**, kao i **testiranje hipoteza / podhipoteza**, provodi se prema unaprijed dogovorenim pravilima koje je nužno slijediti sa svakom skupinom ispitanika na svakom od odabranih kolegija. U **prvom koraku** ispitanici su bili izloženi *predtestu* temeljem kojeg se polaznici dijele u grupe. **Drugi korak** bio je provjeriti jesu li grupe statistički izjednačene. Provjerava se statistička značajnost te donosi zaključak o zadovoljavanju početnih uvjeta istraživanja. U **trećem koraku** ispitanici u okviru svojih grupa koriste jedan od dodijeljenih e-tečajeva (*eksperimentalni* ili *kontrolni*) te su izloženi *posttestu*, pisanoj provjeri znanja kojom je testirano znanje iz nastavnih sadržaja koji su korišteni u eksperimentu.

Ovisno o prosječnom rezultatu iz *posttest* provjere znanja, zaključuje se temeljem t-test analize, uz mogućnost pogreške od 1% ili 5%, da između navedenih ispitanika **postoji ili ne postoji statistički značajna razlika**. Svako istraživanje ima identične korake te su na kraju svakog od njih doneseni zaključci o uspješnosti mjerenja i prihvaćanju **tvrdnji hipoteza i podhipoteza**. *Anketni upitnik* evidentira **mišljenja** ispitanika i **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika. Raspon mogućih odgovora je od 1 do 5, na temelju kojih se može zaključiti imaju li ispitanici ili nemaju pozitivan stav o **motivacijskim elementima** iz računalnih igara. Završni dio koji se uzima u obzir, prilikom zaključka o prihvaćanju ili odbacivanju hipoteza, jest **izvještaj o aktivnosti polaznika** iz *gemificiranog* i *negemificiranog* e-tečaja, koji je prikazan u vidu aktivnosti polaznika.

2. PEDAGOŠKI I TEHNOLOŠKI ASPEKTI E-UČENJA

U ovom poglavlju navode se istraživanja koja pobliže opisuju i definiraju pojam e-učenje. Navodi se nekoliko klasifikacija i vrsta e-učenja, kao i primjera primjene e-učenja u visokoškolskom obrazovanju. Za potrebe empirijskog istraživanja u okviru ove doktorske disertacije odabrana je Moodle platforma koja je dodatno objašnjena u posebnom poglavlju. Također, u kratko su opisane pedagoške teorije vezane uz e-učenje i to: biheviorizam, kognitivizam, konstruktivizam i konektivizam. Slijede teorije i vrste procjena znanja. Ovo poglavlje zaključuje se razmatranjima i budućim razvojem e-učenja, te obrazovnim ciljevima i Bloomovom taksonomijom.

2.1. E-UČENJE

U ovom poglavlju navode se definicije pojma e-učenje. Poglavlje se zaključuje prednostima i nedostacima sustava za e-učenje.

2.1.1. Definiranje e-učenja

E-učenje predstavlja pojam koji nije dobio jednoznačno značenje unatoč njegovim sve većem korištenju u znanstveno-istraživačkim radovima i praktičnim primjerima koji su vidljivi po cijelom svijetu od osnovnoškolskog do visokoškolskog obrazovanja. **Elektronsko učenje** (e-učenje) postala je standardna ne konvencionalna metoda prenošenja znanja gdje **ne postoje ograničenja** po pitanju **vremena, prostora i pristupa** informacijama. Računalna snaga i informacijsko komunikacijska infrastruktura uvelike je olakšala pristup i pretraživanje informacija koje su upotpunjene multimedijским sadržajem, a ponekad i 3D virtualnim prostorima. Još uvijek je vidljivo kako mnogi nastavnici, ali i stručnjaci za informacijsko komunikacijsku tehnologiju (IKT) ne znaju precizno definirati što e-učenje omogućuje i predstavlja. U nastavku rada navodi se nekoliko novijih definicija, ali prvo treba spomenuti zanimljivost koja je vezana za učenje na daljinu.

Prema navodima istraživača Friedland i suradnika (2007.) učenje na daljinu, nastalo je u Engleskoj sredinom 19. stoljeća, točnije **1840.** godine sa Isaac Pitmanom. **Pitman** je svojim studentima zadavao zadatke u kojima su prepisivali kratke poruke iz Biblije, te ih na pregled Pitmanu dostavljali putem pošte. Na taj se način komuniciralo sa studentima bez obzira na udaljenost i prenosilo se znanje. Uočena je brzina **razmjene informacija, ekonomičnost i jednostavnost** primjene obrazovnog sustava koji se **pojavom suvremene tehnologije** sve više potiče i primjenjuje.

Curran (2010.) navodi da su američki akademski nastavnici i znanstveni istraživači bili među prvima koji su koristili elektronsku poštu i World Wide web platformu kao **podršku** njihovim **istraživanjima**, pristupanju **informacijama** i **komuniciranju** s kolegama. Zbog **razvoja informacijsko komunikacijskih** mogućnosti, svoje popularnosti i jednostavnosti korištenja, mnoge obrazovne institucije podržale su trend i priključile se elektroničkoj razmjeni **informacija**, nastavnih **materijala** i **znanja**.

Berardi i Rea (2010.) navode kako je e-učenje metoda poučavanja koja naglašava mogućnosti prenošenja obrazovnog sadržaja putem Interneta ili kroz Internetsku infrastrukturu. Predstavlja **fleksibilno obrazovno rješenje** s obzirom na korisnika, lako se **personalizira** i **široko** je **dostupan** za korištenje. Berardi i Rea govore kako za razvoj sustava za e-učenje, stručnjak treba razviti **integrirani sustav za vježbanje**, dizajniran putem **web tehnologije** koja omogućuje **upravljanje, korištenje** i **širenje** obrazovnih resursa.

Juhary (2012.) ističe kako se e-učenje odnosi na sve aktivnosti podržane informacijsko-komunikacijskim sustavima. U navodi aktivnosti bazirane na Internet i CD-ROM tehnologiji, te interaktivne *online* sustave za poučavanje.

Hussain (2012.) navodi da je glavna ideja e-učenja povezana s načinom na koji se informacijsko-komunikacijska tehnologija koristi za potrebe svih obrazovnih aktivnosti bez obzira bilo to **samostalno** ili u **grupi**, **online** ili **offline**, **sinkrono** ili **asinkrono**, te putem **računalne mreže** ili **lokalno** putem **CD-a**.

U svom istraživanju, Phobun (2010.) navodi definiciju e-učenja gdje je učenje potpomognuto **tehnologijom** i **električnim uređajima** poput računala koji su povezani na lokalnu ili globalnu mrežu s ciljem razmjene vještina i znanja.

Yacob i suradnici (2012.) iznose kako je e-učenje sačinjeno od **svih oblika** učenja i poučavanja koje je temeljeno na **informacijsko-komunikacijskim, elektroničkim** uređajima. Navedeni uređaji **moгу**, ali i **ne moraju** biti **umreženi**, te služe kao medij za implementaciju obrazovnog procesa.

Dharmawansa i suradnici (2013.) govore kako se pojam e-učenja različito tumači u različitim područjima i od strane različitih stručnjaka. Sa stajališta **sveučilišta**, e-učenje je pojam koji predstavlja **specifičnu metodu** kojom se prenose **specifična znanja** i **vještine** studentima **pomoću Interneta**. Za sobom povlači niz prednosti te u nešto manjoj mjeri nedostataka o kojima ima riječi u nastavku rada.

Tîrziu i suradnici (2015.) navode kako Oxford predstavlja pojam e-učenja kao tip učenja koje se oslanja na elektroničke medije, u prvom redu na **Internet**. Navodi se i kako Kanadski koncil za obrazovanje oslovljava pojam e-učenja kao razvitak znanja i vještina pomoću informacijsko-komunikacijske tehnologije, s naglaskom na **interakciji sa sadržajem**, sa obrazovnim **aktivnostima, alatima** i sa **drugim sudionicima** obrazovnog procesa.

Mohammadi i suradnici (2011.) navode kako se za pojam e-učenja često veže informacijsko-komunikacijska tehnologija korištena u svrhu učenja i poučavanja. Također, navode kako se spomenuti pojam može definirati i kao **elektronički sustav** sastavljen od **računala, Interneta** i **multimedijskih CD-a**, kojemu je **cilj smanjiti troškove** obrazovanja.

Bell i Federman (2013.) govore kako je e-učenje područje istraživanja koje je privuklo interes mnogih disciplina društvenih znanosti kao što su upravljanje i komunikacijska, psihologija obrazovanja te računalna i informacijska znanost. Širina područja i različiti ciljevi istraživača ovog pojma, dovelo je do fragmentarnog razumijevanja onoga što e-učenje predstavlja i kako bi se trebalo definirati. Bell i Federman navode kako oni koriste pojam e-učenje za sve oblike **elektroničko podržanog prenošenja znanja**.

Klement i Dostál (2014.) govore kako je percepcija e-učenja **često podvojena** i **nekonzistentna** zbog korištenih tehnoloških rješenja, isto kao i zbog heterogene terminologije koju potiču lingvisti. **Obrazovni proces** podržan informacijsko-komunikacijskom tehnologijom često se ne naziva e-učenjem, već se dolazi do sljedećih pojmova: **Računalno orijentirano treniranje, Internetsko orijentirano treniranje** ili **Web orijentirano treniranje**.

Mozhaeva i suradnici (2014.) navode pojam "**modernog e-učenja**" koji nadilazi aplikacijski pristup odvojenih multimedijskih elemenata i prerasta u **sustav temeljen na odlučivanju** u kojima sustavi za **upravljanje učenjem** (eng. *learning management system, LMS*) i **društvene mreže** (eng. *social networks, SN*) dominiraju.

Hošková-Mayerová i Rosická (2015.) u svojem istraživanju navode se kako se uz pojam e-učenja često veže i **cjeloživotno obrazovanje** zato što se ovakav tip obrazovanja ne kosi s poslovnim ili obiteljskim obvezama s obzirom na to kako se **vrijeme** i **mjesto** za poučavanje **definira individualno**. Hošková-Mayerová i Rosická govore kako se e-učenje, uz promišljanje, **lako kombinira** i s **tradicionalnim** obrazovnim lekcijama, programima za uvježbavanje vještina i ostalim modelima poučavanja koji bi se mogli direktno povezati s ishodima učenja, što se u zadnjih nekoliko godina i naglašava od strane drugih istraživača.

Burić i Grubešić (2010.) navode kako je e-učenje (eng. *e-learning*) jedan od pojmova s prefiksom "e" koji se u zadnje vrijeme vrlo često spominje, kao i njegove brojne interpretacije kao što su:

- Experience Learning (**iskustveno** učenje)
- Everywhere Learning (učenje "**posvuda**")
- Enhanced Learning (**unaprijeđeno**, bolje učenje)
- Extended Learning (**prošireno** učenje)

Sveučilište u Zagrebu donijelo je dokument pod nazivom "**Strategija e-učenja 2007-2010**" u kojem navodi se definicija e-učenja koja glasi: "*E-učenje je proces obrazovanja (proces učenja i podučavanja) uz uporabu **informacijske i komunikacijske tehnologije**, koja doprinosi **unapređenju kvalitete toga procesa i kvalitete ishoda obrazovanja.***"

Sveučilište u Splitu unutar svog dokumenta skraćenog naziva "**Strategija razvitka za razdoblje 2011-2015**" citira definiciju iz "Strategije e-učenja 2007.-2010." Sveučilišta u Zagrebu. Unutar dokumenta pod nazivom "**Strategija Sveučilišta u Splitu 2015-2020**" navode se nekoliko strateških ciljeva gdje je drugi cilj usmjeren na programe cjeloživotnog učenja te učenja na daljinu. Prvi zadatak navedenog cilja govori o **povećanju** postotka **nastavnog sadržaja** kojeg bi studenti mogli pratiti kroz **e-učenje (barem 25%)**. Vrijednost cilja odnosi se na sve kolegije, svakog studijskog programa. Drugi zadatak cilja govori o organiziranju zajedničkog sustava e-učenja Sveučilišta koji do sada nije postojao.

Sveučilište u Zadru sastavlja dokument pod nazivom "**Strategija Sveučilišta u Zadru 2011-2017**" u kojem navodi opis e-učenja i učenja na daljinu koji navodi se u nastavku: "*E-učenje i učenje na daljinu predstavlja nužan iskorak koji Sveučilište u dogledno vrijeme treba napraviti. Perspektiva ovakvog modela učenja, prilagodba potencijalnim studentima i doprinos zajednici od iznimnog je značenja. Učenje na daljinu jedna je od kvalitativnih komponenti rada Sveučilišta koja dovodi do **sinergije rada u učionici i rada s novim tehnologijama** te omogućuje studentima **kvalitetniji dostup** do nastavnih gradiva te **brže i jednostavnije** svladavanje **studentskih obveza.***" Iz SWOT analize novijeg dokumenta "**Strategija Sveučilišta u Zadru 2015-2019**" može se zaključiti kako je sustav za e-učenje nedovoljno razvijen, te se njegov razvoj smatra jednim od strateških ciljeva institucije.

Navedene dokumente pronađite u pregledu literature na strani 326.

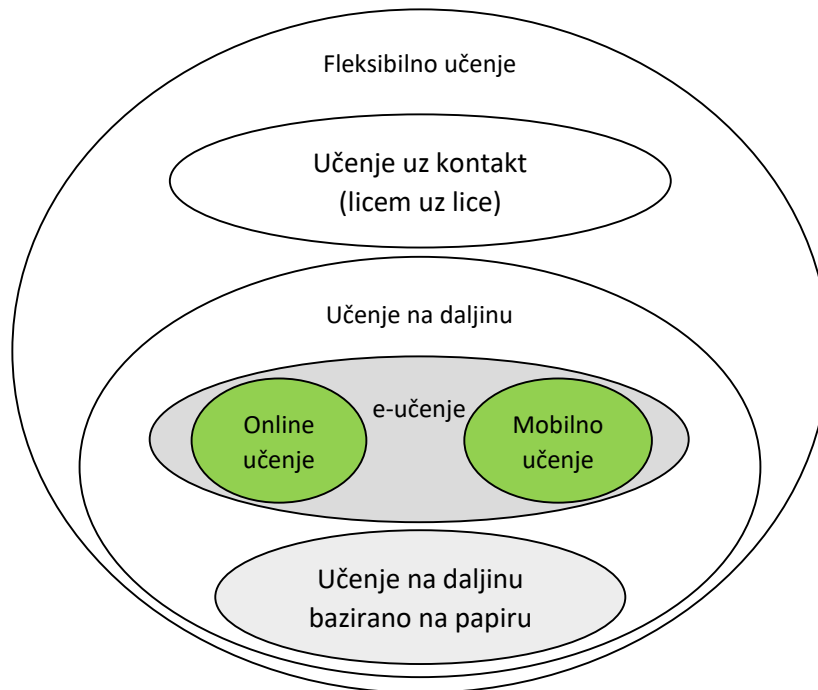
Sveučilište u Rijeci sastavlja dokument pod nazivom "**Strategija uvođenja e-učenja na Sveučilištu u Rijeci 2006-2010**" u kojem navodi se definicija e-učenja koja glasi: "*E-učenje je pojam koji opisuje **obrazovni proces** unaprijeđen uporabom novih **informacijsko-komunikacijskih tehnologija**. Riječ je o bilo kojem obliku **učenja, poučavanja ili obrazovanja** koji je potpomognut prvenstveno onim **tehnologijama** koje se **temelje na Internetu (webu)**."* Jedan od ciljeva vidljiv iz dokumenta pod nazivom "**Strategija razvoja Sveučilišta u Rijeci 2014-2020**" jest povećati udio e-učenja u studijskim programima. Razina koja se želi postići je da 50% svakoga studijskog programa upotrebljava napredne alate za e-učenje (e-tečaj, *online* kolegij, multimedijalni sadržaji, e-literatura, video materijali).

Unutar dokumenta "**Strategija obrazovanja, znanosti i tehnologije**" koji je sastavila Vlada RH 2014 navodi se kako "*E-učenje i obrazovanje pruža **vremenski i prostorno fleksibilan pristup** ažurnim i aktualnim **multimedijalnim i interaktivnim nastavnim materijalima**, a integrirano u nastavu omogućuje **dinamičko korištenje** hrvatskih i svjetskih repozitorija obrazovnih sadržaja, digitalnih knjižnica, arhiva i muzeja". "Širenjem e-učenja i obrazovanja raste uloga i **važnost nastavnika**, kao **mentora, koordinatora i poticatelja** obrazovnog procesa. E-učenje omogućuje da **u središtu** obrazovnog procesa bude **polaznik**, koji preuzima **aktivnu ulogu i odgovornost** za ishode obrazovanja."*

Moore i suradnici (2010.) prilikom definiranja pojma e-učenja navode sljedeći niz termina: "*online learning, e-Learning, technology, mediated learning, online collaborative learning, virtual learning, web-based learning, online course/learning, web-based learning, web-based training, learning objects or distance learning*". Navedeni termini, u njihovom izvornom obliku, sadrže dvije zajedničke osobine, a to je **fizička udaljenost** između nastavnika i studenta, te **informacijsko-komunikacijska infrastruktura** bazirana na **Internetskoj tehnologiji**. Moore i suradnici (2010.) povezuju e-učenje, **online** učenje i **mobilno** učenje te govore kako se pod *online* učenje smatra proces koji se odvija isključivo putem **Internetske komunikacije**, dok je mobilno učenje vezano samo za **mobilne računalne uređaje**, te su obje kategorije **podskupina e-učenja**.

Navedene dokumente pronađite u pregledu literature na strani 326.

Brown (2003.) ističe kako dodatnom razumijevanju e-učenja može doprinijeti slika odnosa srodnih oblika prenošenja znanja što je prikazano na sljedećoj slici, gdje se može uočiti kako je e-učenje podskup učenja na daljinu, ali isto tako predstavlja ravnopravnost s mobilnim učenjem koje se zbog raširenosti 4G mobilnih uređaja sve više koristi u virtualnim učionica.



Slika 2. Fleksibilno učenje i prikaz potkategorija (prilagođeno prema Brown, 2003.)

Iz slike 2. je vidljivo kako je e-učenje podskup učenja na daljinu koje može biti temeljeno na Internetskim tehnologijama ili tradicionalnom pristupu korištenjem papira. Brown (2003.) navodi da je e-učenje makro koncept koji uključuje *online* učenje i učenje pomoću mobilnih uređaja. Mobilni uređaji mogu biti prijenosna računala, tableti i mobiteli.

Zaključuje se kako iz ranijih navoda ne postoji **jedinstvena definicija** pojma e-učenje. Sličnosti u značenjima i osnovnim principima provođenja obrazovnog procesa postoje, isto kao i **informacijsko-komunikacijska** tehnologija koja je uz **Internetsku** infrastrukturu glavni posrednik i platforma navedenog pristupa učenju.

U nastavku poglavlja navode se dvije tablice koje ukazuju na prednosti i probleme u primjeni e-učenja u obrazovnim sustavima. Prva tablica ističe odnos prednosti e-učenja s aspekta nastavnika i studenata, dok se druga temelji na usporedbi koristi i mogućih problema prilikom korištenja e-tečaja u obrazovanju.

Unutar dokumenta pod nazivom "Razvoj vještina kroz e-učenje", EU - IPA IV, spominju se prednosti korištenja e-učenja za nastavnike i polaznike.

Tablica 1. Prednosti e-učenja s aspekta nastavnika i studenata (izvor: autor disertacije)

Prednosti za nastavnike	Prednosti za studente
Korištenje sustava za e-učenje za pripremu , te kao pomagalo u nastavi	Mogućnost ponavljanja i provjere znanja nakon završetka e-tečaja
Efikasniji način praćenja napretka i rezultata studentskih aktivnosti i postignuća	Autonomija pristupa (tempo učenja, količina) nastavnim materijalima
Smanjena potreba za fizičkim učionicama	Vremenska i prostorna dostupnost nastavnim materijalima
Interakcija između nastavnika i studenata	Interakcija između studenata međusobno
Sudjelovanje svih sudionika u razmjeni informacija, mišljenja i znanja	Istovremeni pristup nastavnim materijalima (više sudionika u istom trenutku)
Pozitivan utjecaj na informatičku pismenost nastavnika i polaznika	
Niži troškovi u odnosu na klasičnu nastavu za otprilike 40% (Fry, 2001.)	
Trenutna povratna informacija i stanje uspješnosti studentskih aktivnosti	

Tablica 2. Koristi i mogući problemi e-tečaja (izvor: autor disertacije)

Koristi e-tečaja	Problemi e-tečaja
Vremenska i prostorna fleksibilnost	Kvaliteta i dostupnost sadržaja
Financijski isplativ	Navike i kultura u društvu
Prilagodljiv korisniku u njegovim potrebama	Tehnologija i računalna oprema
Kolaboracijsko okruženje	Individualni pristup
Neograničeno korištenje obrazovnih materijala	Standardizacija e-tečaja
Jednostavna provjera znanja	Predznanja korisnika
Interakcija unutar sustava.	Odgovornost korisnika
Povratna informacija	Autorska prava
Kombinacija statičnih i dinamičnih materijala	Promjene u institucijama

Iz priložene tablice vidljivo je kako je **pristup** informacijama **slobodan**, bez obzira o doba dana ili noći, isto tako bez obzira na udaljenost ili status korisnika. **Troškovi** prostora, transporta i popratnih energenata su **smanjeni** jer je sustav znanja i informacija postavljen na Internetski dostupnim stranicama, gdje je korisniku za pristup resursima potreban jedino mobilni uređaj ili računalo. Korisnik bira **vrijeme i mjesto**, te kojim će informacijama ili aktivnostima pristupati.

Sustav namijenjen e-učenju **fizički odvaja** korisnike i eksperte te stvara **virtualnu zajednicu** gdje je moguća suradnja, dijeljenje sadržaja, iskustva, mišljenja i znanja. Interakcija i transparentnost u kojoj svaki korisnik vidi svoj rad, a i cjelinu dostupna je i ponekad poželjna mogućnost. Ako nije drugačije postavljeno, **resursi** su korisniku **dostupni nebrojno puta**, često su **interaktivni** te se mogu zaustaviti ili izdvojeno pregledavati. **Provjera** znanja je jednostavna koristeći testove, samostalne ili grupne zadatke, upitnike, kvizove, računalne igre koje su uključene u obrazovni sustav. **Interakcija** unutar sustava osigurana je pomoću **dinamično generiranih sadržaja** u vidu seminarskih radova, blogova, foruma i dr. Povratna informacija osmišljena je u vidu trenutnih stanja bodova i pokazatelja uspjeha pojedine aktivnosti ili cjeline. Za razliku od knjiga, materijali za e-učenje sastavljeni su od **multimedijских elemenata** koji se proširuju **virtualnim 3D prostorima** u svrhu bolje prezentacije nastavnih materijala.

Uz brojne prednosti po pitanju vremenske i prostorne fleksibilnosti uočeni su i **potencijalni problemi** s kojima se korisnik može suočiti. **Kvaliteta sadržaja** ne ovisi o sustavu za e-učenje već o **nastavnom osoblju** koje nije uvijek sklono prihvaćanju novijih metoda prenošenja znanja te i u skladu s time ne pridodaje dovoljno vremena u pripremi nastavnih materijala koje sustav za e-učenje koristi. **Dostupnost sadržaja** može biti problem zbog **tehničkih zahtjeva** i nastavnika i polaznika e-tečaja. Za funkcioniranje sustava potrebna je stalna električna, računalna i Internetska infrastruktura. **Navike i kultura** učenja mijenjaju se od države do države što može rezultirati odbojnošću za sadržaj koji je kreiran po neprihvaćenim standardima društva. **Tehnologija i tehnološka rješenja** mogu biti izvor problema jer se od korisnika traže minimalni uvjeti koji moraju biti zadovoljeni za pristupanje e-tečaju. Računalna oprema nije uvijek pouzdana čime se, ako dođe i do kratkotrajnog kvara, narušava trenutak u kojem je student koncentriran i obrazovanje postaje otežana. **Principi učenja** su različiti, kao i zahtjevi studenata po pitanju samostalnog ili kolaboracijskog pristupa rješavanju zadataka.

Sustavi za e-učenje međusobno se mogu **razlikovati** po kvaliteti, dizajnu, nastavnim aktivnostima i sl. čime se na negativan način može utjecati na očekivanja, zadovoljstvo i motivaciju studenata. Sustav za e-učenje od korisnika zahtjeva **minimalnu informatičku pismenost** i ne rijetko poznavanje engleskog jezika te više ili manje stručna određena znanja i vještine kako bi se njime mogli koristiti. Samostalno određivanje kada, gdje i što učiti za sobom dovodi **veću odgovornost** po pitanju odrađivanja nastavnih aktivnosti, planiranja vremena i samo procjene vlastitih mogućnosti. Nastavno osoblje koje nije u potpunosti osposobljeno za kreiranjem digitalnih nastavnih sadržaja može doći u sukob s **licenciranjem nastavnih**

materijala koji su javno dostupni. **Organizacijske promjene i stručno usavršavanje** nastavnika predstavljaju kritične točke u instituciji zbog **tromosti sustava** i neprihvatanja novijih i **izmijenjenih principa** prenošenja znanja.

Detaljnije pobrojani nedostaci navode se, u knjizi Ćukušić i Jadrić (2012.) pod nazivom "e-učenje: koncept i primjena". Autori knjige naglašavaju kako su navedeni nedostaci realne prepreke o kojima nastavno osoblje i tehnička podrška trebaju voditi brigu jer predstavljaju vrlo osjetljivo područje koje uvelike može motivirati, ali i demotivirati sudionike (polaznike i nastavnike) e-tečaja.

2.1.2. Elementi e-učenja

U ovom poglavlju navode se istraživački radovi u kojima se opisuju osnovni elementi e-učenja. **Sustav za upravljanje učenjem** prvi je od tri elemenata e-učenja. Slijede **sadržaji i aktivnosti tečaja i suradnja između sudionika** sustava za e-učenje. Poglavlje se zaključuje konceptualnim okvirom za e-učenje.

2.1.2.1. Sustav za upravljanje učenjem (LMS)

Poulova (2015.) ističe kako se sustavi za upravljanje sastoje od aplikacijskih rješenja koja su u mogućnosti kreirati **virtualan obrazovni prostor i simulirati učenje** koje je studentu dostupno **svakim danom** u godini, **bez obzira na mjesto i vrijeme pristupa**. U obrazovnom kontekstu vidljivo je kako se informacijsko-komunikacijska tehnologija može koristiti na razne načine i to kao alat za **prenošenja znanja** metodom koja **ne uključuje fizičku prisutnost** polaznika. Može se koristiti i kao **administracijski alat** te kao **alat za kreiranje obrazovnog okruženja**. IKT predstavlja nužan preduvjet za provođenje navedenog oblika poučavanja, gdje je **pozicija nastavnika nezamjenjiva** bez obzira na njegovu ulogu u sustavu.

Sustav za upravljanje učenjem je **programsko rješenje** koje omogućuje **administriranje** procesa učenja i poučavanja te omogućuje **povezivanje** obrazovnog procesa s postojećim informacijskim sustavom pojedinca ili organizacije. Osmišljen je kao **centralni program** koji omogućuje pojedincu, grupi ili organizaciji **povezivanje u obrazovno okruženje** koje ne ovisi o **mjestu i vremenu pristupa** materijalima. Automatiziranim postupkom obavlja registraciju i praćenje korisnika, kao i njegovih aktivnosti te omogućuje **trenutnu povratnu informaciju** i korisniku i nastavniku e-tečaja. Bilježi cjelokupnu **statistiku** o pojedincu ili grupi polaznika, omogućuje generiranje izvješća o uspjehu i dodjelu diploma ili certifikata po završetku e-tečaja.

LMS omogućuje nastavnom osoblju **uređivanje izgleda** i uključivanje mogućnosti kojim nastavnik provjerava razinu naučenog nastavnog sadržaja, ali ujedno omogućuje **samokontrolu** i **samo procjenu** studentovog znanja, neovisno o nastavniku. Za efikasan rad s LMS sustavom, nastavno osoblje trebalo bi **komunicirati s administratorima** te **uskладiti** potrebe i mogućnosti e-tečaja. Mogućnosti LMS sustava navode se u tablici 3.

Nastavnik definira način na koji se korisnik ili student uključuje u e-tečaj, nakon čega se pojedinac uključuje u sustav koji ga prati od početka pa sve do završetka rada u e-tečaju. Iscrpni statistički podaci nastavniku su na raspolaganju s ciljem **pravovremenog reagiranja**, **usputnog procjenjivanja** i **završnog ocjenjivanja** studenta. LMS evidentira vrijeme pristupanja i vrijeme provedeno u sustavu, kao i uspješnost nastavnih aktivnosti te sve podatke o svakom studentu zapisuje u bazu podataka. Nastavnik definira koji podaci o praćenju studentovog rada su javno ili privatno **dostupni**. Moguće je definirati na koji način studenti **međusobno komuniciraju**, što u sustavu mogu **mijenjati** i što im se prikazuje u e-tečaju po pitanju **uspješnosti** pojedinca ili grupe **polaznika**.

Awang (2012.), Barge (2014.), Oproiu (2015.) i drugi navode kako se LMS pokazao kao vrlo korisnim alatom za mnoge škole i visokoškolske institucije u proteklih 10-tak godina. Pojednostavljen je način prezentacije informacija i edukativnog sadržaja isto kao i pristupa dizajnu raznih sveučilišnih kolegija. Značajnu ulogu ima i u pogledu poticanja komunikacije između objekata nastavnog procesa, na prvom mjestu studenata i nastavnika.

Glavne prednosti korištenja sustava za upravljanje učenjem navedene su u nastavku:

- a) **Besplatan pristup** - za korištenje sustava nije potrebno plaćati godišnju pretplatu ili podmirivati troškove licenciranja.
- b) **Fleksibilnost** - proizvodi otvorenog koda fleksibilni su po pitanju izmjena i prilagodbe potrebama institucije u kojoj se sustav koristi. Novi alati i funkcionalna rješenja mogu se lako preuzeti i implementirati u postojeći sustav.
- c) **Korisnička podrška** - sustav se temelji na velikom broju mreža koje međusobno surađuju i pomažu u rješavanju mogućih slabosti te se tako povećava stabilnost i rasprostranjenost sustava. Korisnička podrška bazira se na volontiranju i uglavnom se sva komunikacija odvija putem foruma.
- d) **Učestale primjene i nadogradnje** - korisnička i razvojna podrška osigurava redovite nadogradnje sustava u koje se ubrajaju institucionalna rješenja, kao i rješenja volontera koji razvijaju nove ili poboljšavaju postojeće alate za prenošenje informacija i znanja.

- e) **Porezni poticaj** - vlade mnogih država osigurale su porezne olakšice za korisnike programskih proizvoda baziranih na otvorenom kodu.
- f) **Popratna dokumentacija** - sva pomoć i dokumentacija koja je potrebna za učenje i korištenje sustava otvorenog koda za upravljanje učenjem dostupna je na mnogim svjetskim jezicima i na internatskim adresama.

Tablica 3. Mogućnosti LMS sustava (prilagođeno prema Coates, 2005.; Balogh, 2011.)

Upravljanje korisnicima	Generiranje izvješća
Upravljanje ulogama	Testiranje znanja i ocjenjivanje uspješnosti
Upravljanje mentorima	Razmjenu informacija među sudionicima
Kreiranje objekata učenja	Diskusijske grupe, Chat, računalne igre
Upravljanje objektima učenja	Najave događaja i još mnogo drugih aktivnosti

Broj država koje prepoznaju e-učenje kao standard modernog obrazovanja je u porastu i vrlo je čest primjer u visokom obrazovanju. S obzirom na to kako se radi o programskom rješenju koje je moguće plasirati na svjetsko tržište, LMS sustavi mogu se podijeliti na **komercijalna rješenja** (WebCT, BlackBoard, IntraLearn i druga) te javno dostupna, **besplatna aplikacijska rješenja** (Moodle, Claroline, Ilias i druga).

2.1.2.2. Sadržaj e-tečaja

Sadržaj tečaja predstavlja **bazu informacija** na temelju koje se stvaraju nova znanja, te se s pravom može reći kako je sadržaj tečaja **ključan element** svakog e-tečaja. LMS sustav svakom nadogradnjom omogućuje sve više mogućnosti za prikaz i prezentiranje sadržaja gdje multimedijски elementi (tekst, grafika, zvuk, video i animacija) predstavljaju standard nastavnog sadržaja. Autor disertacije smatra kako se nastavni materijali trebaju osmisliti na **kreativan način** i približiti iz općenitog u **specifično okruženje** temeljeno na praktičnim primjerima s kojima se studenti mogu **poistovjetiti**, koje mogu **razumjeti** i **prepoznati** u okolini izvan e-tečaja. Navedeno je moguće s obzirom na stupanj razvoja informacijsko-komunikacijske tehnologije, širokopojasnog Interneta i sklopovskih mogućnosti računala.

Nadalje, **nastavni materijal** treba biti **interaktivan** koliko je to god moguće i stalno dovoditi u pitanje **shvaćanje sadržaja** i **povezivanje novih informacija s postojećim znanjem** svakog polaznika e-tečaja. Polaznik tečaja ima slobodu izbora nastavnih materijala, ali mora poznavati **pravila** i **uvjete** korištenja sadržaja tečaja.

Ispravnost akcija i vlastitih aktivnosti nad nastavnim sadržajem moguće je pratiti kroz sustav povratnih informacija koji je sastavni dio svakog obrazovnog sustava. Obrazovni proces može biti orijentiran na studenta ili na nastavnika, te dok se razmišlja o e-učenju, dobro bi bilo uravnoteženo koristiti oba aspekta i oblika poučavanja.

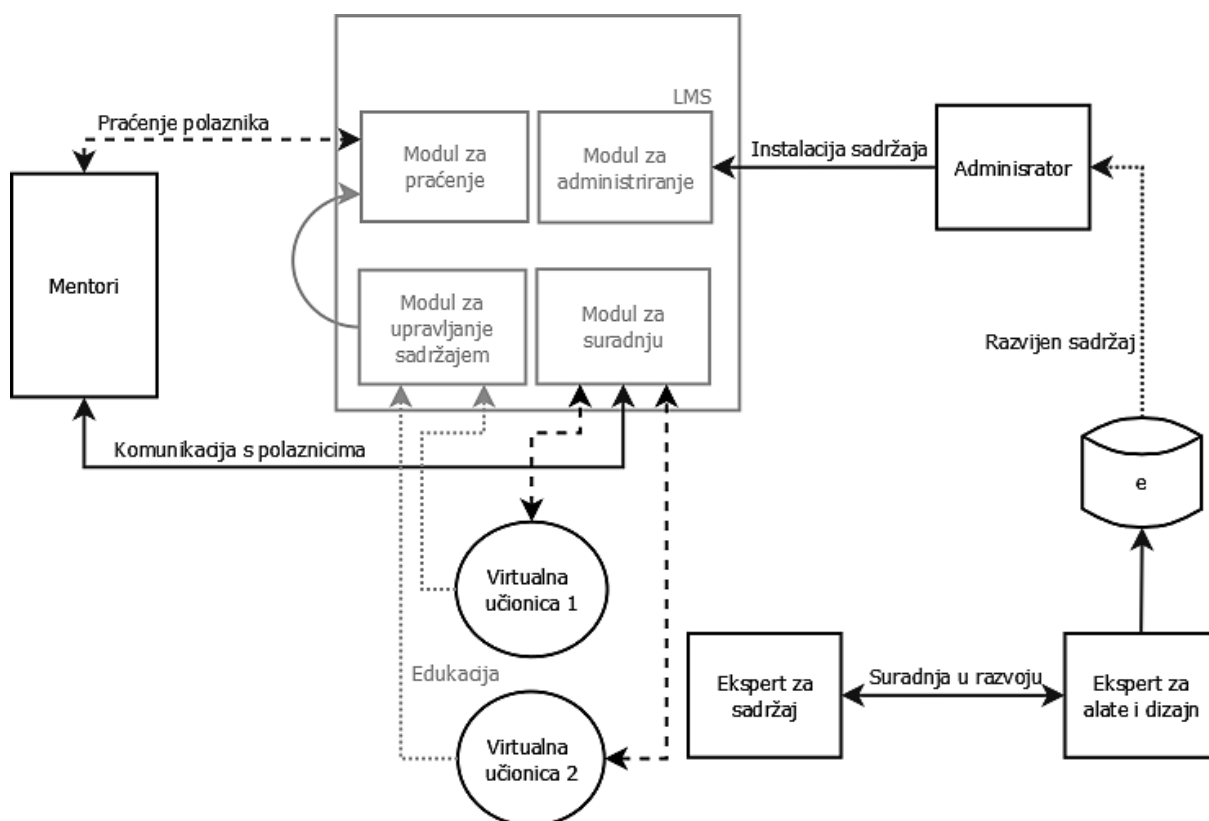
Fallon (2002.) navodi da se sadržaji e-tečaja mogu promatrati na dva načina: **konceptualno** i **fizički**. "Fizička vrsta sadržaja odnosi se na samu isporuku sadržaja, odnosno uključuje **datoteke, baze podataka, programsku podršku** za upravljanje bazama podataka, tj. sve što postoji fizički (elektronski). Konceptualna vrsta sadržaja odnosi se na način **organiziranja sadržaja** u kolegije, lekcije i sl., gdje je najmanji dio takvog sadržaja učenja nazvan objektom učenja."

2.1.2.3. Suradnja u e-tečaju

Komunikacija u e-tečaju može biti **sinkrona** i **asinkrona** ovisno o tipu aktivnosti koju polaznik ili nastavnik odabere za prijenos informacije. Komunikacija je moguća između svih sudionika e-tečaja (nastavnik, student, grupa polaznika) i **najčešće je asinkrona**, ali i **dvosmjerna** te predstavlja temelj odnosa koji se zasniva na međusobnoj suradnji. Svi sudionici e-tečaja dijele **zajednički cilj**, a to je stjecanje novog ili proširivanje postojećeg znanja ili vještina. Suradnja među sudionicima je podržana i praćena od strane LMS sustava čime se polaznicima omogućuje međusobno povezivanje i poticanje za ostvarivanjem globalnog cilja, a samim time i boljih individualnih rezultata. Postoje alati za razmjenu iskustva, savjeta, informacija i znanja unutar LMS sustava o kojima brine nastavnik e-tečaja u suradnji s administratorom sustava. Prema EU-IPA IV (2016.) koncept e-učenja može se promatrati prema navedenom dokumentu "Razvoj vještina kroz e-učenje" koji je vidljiv iz tablice 4. i grafičkog prikaza u nastavku rada na slici 3.

Tablica 4. Odnos između elemenata e-učenja

Platforma za e-tečaj	Sadržaj e-tečaja	Uloge e-tečaja
LMS	Gotovi tečajevi	Polaznici
Alati za izradu sadržaja	<i>Online</i> knjige	Autori sadržaja i mentori
	<i>Online</i> materijali	Administratori obrazovanja
	<i>Online</i> predavanja	Sustavska podrška



Slika 3. Konceptualan okvir e-učenja (izvor: prilagođeno prema EU-IPA IV, 2016.)

2.1.3. Klasifikacija i vrste e-učenja

Prema dokumentu EU-IPA IV (2014.): Učenje na daljinu, postupak provođenja e-učenja moguće je promatrati s obzirom na razne činitelje, dok se jedan posebno ističe, a to je vrsta interakcije između nastavnika i polaznika tog e-tečaja. Samim time, može se govoriti o **sinkronom i asinkronom e-učenju**.

Sinkrono e-učenje (Ćukušić i Jadrić, 2012.):

- omogućuje **dvostranu komunikaciju** između nastavnika i polaznika
- ima **niže troškove** organiziranja, provođenja, praćenja i vrednovanja nastave
- omogućuje **brzu razmjenu** informacija, nastavnih materijala i razmjenu mišljenja
- **ne podržava fizički kontakt** niti **neverbalnu komunikaciju**

Sinkrono e-učenje prema Krpan (2010.): "Odvija se u **virtualnoj učionici**, a zasnovano je na **istovremenom** pristupu sadržajima od strane svih sudionika, u realnom vremenu. Može uključiti web orijentirane **video konferencije** i **online chat**, a iako nema prostornog ograničenja, **postoji vremensko ograničenje** s obzirom na to da se učenje događa u točno određenim vremenskim terminima kada moraju biti prisutni i učenici i učitelji".

Prema dokumentu EU-IPA IV (2014.): Učenje na daljinu, prilikom odabira sinkronog načina provođenja e-učenja, nastavnik ili administrator tečaja, treba aktivnosti **koordinirati** ovisno o grupi polaznika koji imaju različitu **geografsku poziciju**, te je nužno organizirati e-tečaj na način kako svi sudionici imaju mogućnost sudjelovati u sličnim uvjetima. U tu svrhu treba razmotriti i proučiti **alate za sinkronu komunikaciju** koji omogućuju komunikaciju u realnom vremenu, pri čemu polaznici e-tečaja moraju biti spojeni na mrežu u isto vrijeme. Rezultat navedenog je pristupanje polaznika u realnom vremenu e-tečaju gdje ostvaruje vezu s nastavnikom tečaja, te se **obrazovni proces i postupak učenja razlikuje samo po mjestu** na kojem se **polaznici nalaze**.

Asinkrono e-učenje (Ćukušić i Jadrić, 2012.):

- omogućuje korištenje nastavnih sadržaja **u trenutku** kada je to polazniku **potrebno**
- nastavnikova **prisutnost nije potrebna**
- **sadržaj** mora biti **interesantan** i mora podržavati veću **dubinu informacija**

Asinkrono e-učenje prema Krpan (2010.): *"Može se provoditi u bilo koje vrijeme, nema vremenskih ograničenja, a odnosi se na metode učenja kada su učenik i učitelj u interakciji koja može biti naizmjenice, dakle, ne moraju biti prisutni istovremeno u točno određenom vremenu. Takav način učenja je vjerojatno zanimljiviji jer je jeftiniji i moguće je ponovo koristiti već gotove sadržaje. Primjeri takvih aktivnosti su: e-mail, forum, interesne grupe,..."*

Prema dokumentu EU-IPA IV (2014.): Učenje na daljinu, prilikom odabira asinkronog načina provođenja e-učenja, nastavnik ili administrator tečaja treba polaznicima omogućiti **pristup** virtualnoj učionici u **svakom trenutku**, kao i **sudjelovanje** u raspravama pri čemu polaznik **ne mora trenutno odgovarati**. Ima mogućnost napustiti raspravu, proučiti tematiku, vratiti se u raspravu i napisati osvrt. U tu svrhu treba razmotriti i proučiti **alate za asinkronu komunikaciju** kod kojih se komunikacija ne odvija u realnom vremenu i gdje korisnici ne moraju biti spojeni na mrežu u isto vrijeme. Navedeni alati prikazani su u tablici 5.

Tablica 5. Primjeri alata za sinkronu i asinkronu komunikaciju

Alati za sinkronu komunikaciju	Alati za asinkronu komunikaciju
Razmjena izravnih poruka	Forum za rasprave
Chat	Elektronička pošta
Elektroničke ploče	Blogovi
Audio / video konferencije	News grupe
Virtualna učionica	Wiki

E-učenje može se promatrati i s aspekta vremena i mjesta pristupa e-tečaju i nastavnim materijalima te se može podijeliti prema tablici 6. ove disertacije (Ćukušić i Jadrić, 2012.).

Tablica 6. Mogućnosti korištenja e-tečaja

Naziv	Svojstvo
Isto vrijeme i isto mjesto	<input type="checkbox"/> Predstavlja klasičnu nastavu, gdje su svi polaznici u istoj učionici.
Isto vrijeme i različito mjesto	<input type="checkbox"/> Polaznici mogu pristupiti nastavnom sadržaju u točno zadano vrijeme, gdje mjesto s kojeg se pristupa nije definirano i ovisi o poziciji polaznika čime se omogućuje sinkroni oblik e-učenja (npr. webinar) i
Različito vrijeme i isto mjesto	<input type="checkbox"/> Polaznici imaju slobodu odabira vremena pristupa nastavnom sadržaju, ali je lokacija statična (npr. zgrada fakulteta)
Različito vrijeme i različito mjesto	<input type="checkbox"/> Polaznici nisu ograničeni niti na vrijeme niti na mjesto s kojeg pristupaju nastavnim sadržajima čime se omogućuje asinkroni oblik e-učenja.

Zbog dostupnosti i lakoće korištenja IKT-e, pregledom literature uočeno je kako se e-obrazovanom procesu može klasificirati s obzirom na **intenzitet** i **način korištenja** IKT-e, te se razlikuju sljedeći oblici koji su navedeni u tablici 7., Mihaljišin (2016.):

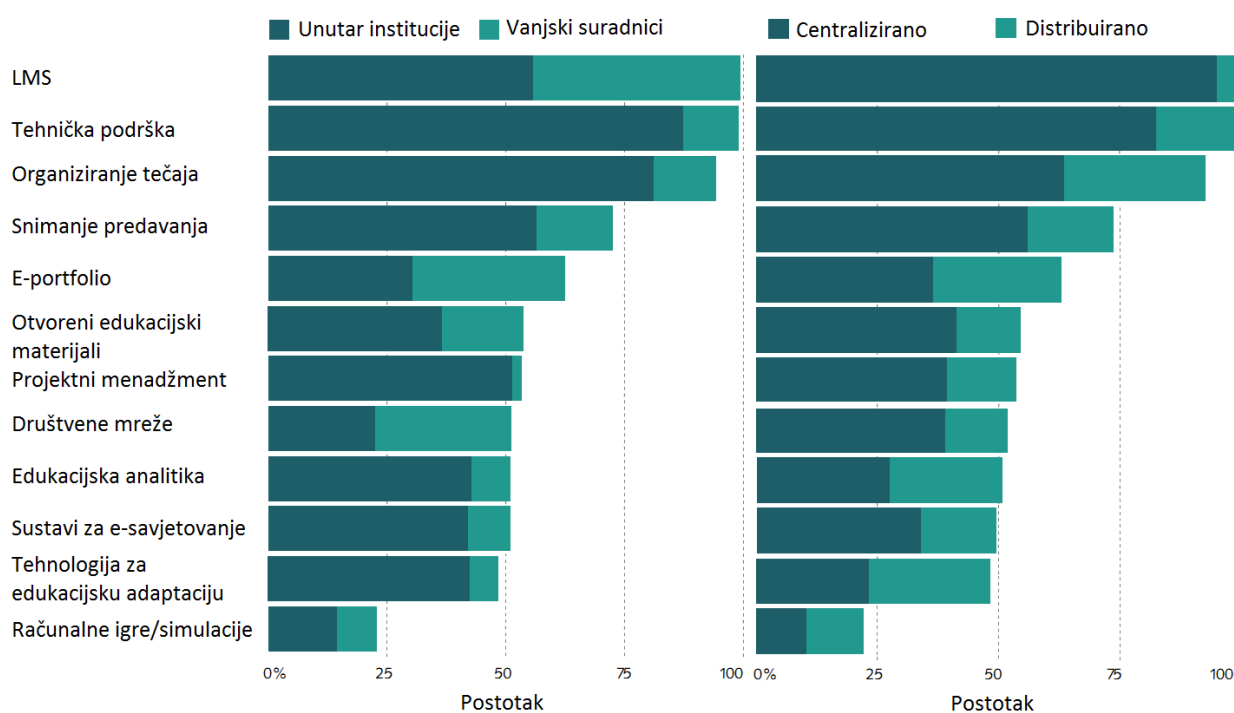
Tablica 7. Klasifikacija obrazovnog procesa

Naziv	Svojstvo
Klasična nastava u učionici	<input type="checkbox"/> licem u lice <input type="checkbox"/> tehnologija složenija od procesora teksta nije podržana u ovakvom obliku nastave
Nastava podržana IKT-om	<input type="checkbox"/> licem u lice <input type="checkbox"/> CD-ROM aplikacije, multimedijske prezentacije, HTTP, web usluge i sadržaji
Mješovita ili hibridna nastava	<input type="checkbox"/> kombinacija klasične nastave i nastave potpomognute IKT i web tehnologijom
Online nastava	<input type="checkbox"/> Web mjesta i videokonferencije <input type="checkbox"/> nastava koja se izvodi isključivo pomoću IKT i web tehnologijom

2.1.4. E-učenje u visokoškolskom obrazovanju

Bichsel (2013.), u svom istraživanju, kojemu je pristupilo 311 obrazovnih institucija, navodi sljedeće zaključke i grafički odnos prikazan na slici 4.:

- Gotovo sve institucije imaju **interes** za e-učenjem.
- **80%** ispitanih institucija posjeduje **barem jedan** *online* tečaj.
- Potvrđuje se **prednost dostupnosti** tečajevima bez obzira na prostornu udaljenost.
- Za učinkovitu implementaciju e-učenja poželjno je koristiti **centraliziran** model gdje se distribucijski pristup može omogućiti prema potrebama određenog programa.
- **Programska podrška** se udvostručila i evidentirana je potražnja za **IT stručnjacima** iz područja e-učenja.
- Uočen je **nesklad** između onoga što studenti **trebaju** i onoga što im obrazovna **institucija omogućuje** po pitanju IT infrastrukture.
- Naglašava se važnost odabira IT tehnologije za e-učenje je koja je **fleksibilna, jednostavna** za korištenje i **sigurna** po pitanju zaštite studentskih podataka.
- Zabrinutost je usmjerena **nedovoljno stručnom osoblju** koje koristi sustave za e-učenje.
- Zabrinutost je usmjerena **ishodima učenja** bez obzira na metodu poučavanja.
- Male institucije imaju veći potencijal **iskorištavanja** mogućnosti e-učenja i jednostavniju **implementaciju**.



Slika 4. Pristup i korištenje servisa za e-učenje (prilagođeno prema Bichsel, 2013.)

Na **lijevoj strani** grafikona prikazan je odnos između **servisa za e-učenje** koji se mogu provoditi **unutar institucije** ili putem **vanjskih suradnika**. Vidljivo je kako više od jedne četvrtine obrazovnih institucija koristi strana **otvorena** ili **komercijalna** rješenja po pitanju LMS sustava, e-portfelja i društvenih mreža. **Materijale** i **e-tečajeve** obrazovne institucije **same razvijaju** i to u postotku od 81%, isto kao i pružanje tehničke podrške u iznosu od 87%. Desna strana grafikona pokazuje odnos između servisa za e-učenje koji mogu biti **centralizirani** ili **distribuirani**. Vidljivo je kako više od 90% obrazovnih institucija **same nadgledaju i provode** LMS, tehničku podršku i vođenje e-tečaja.

Gaebel i suradnici (2014.), unutar istraživanja od strane *European University Association* koje se provodilo između 2013-2014. godine, navode se kako je od **800 članica** ovog udruženja nije 249 odgovorilo pozitivno na zahtjev za popunjavanjem ankete usmjerene e-učenju i popratnim strategijama. U nastavku rada, u tablicama 8. i 9., navode se rezultati istraživanja. Broj obrazovnih institucija koja su uključena u istraživanje prikazan je u sljedećoj tablici. U okviru 249 institucija koje su pristale na popunjavanje *anketnog upitnika*, uključena su i **dva Hrvatska sveučilišta**.

Tablica 8. Broj obrazovnih institucija (prilagođeno prema Gaebel, 2014.)

Veličina visoko obrazovne institucije	Broj institucija	% u uzorku
Mala (0 – 7.499 studenata)	41	17
Srednja (7.500 – 24.999 studenata)	131	53
Velika (25.000 – 49.999 studenata)	54	22
Vrlo velika (preko 49.999 studenata)	19	8
Nepoznata	4	2
Ukupno	249	100%

Tablica 9. Profil obrazovnih institucija koje su sudjelovale u anketi za e-učenje
(prilagođeno prema Gaebel, 2014.)

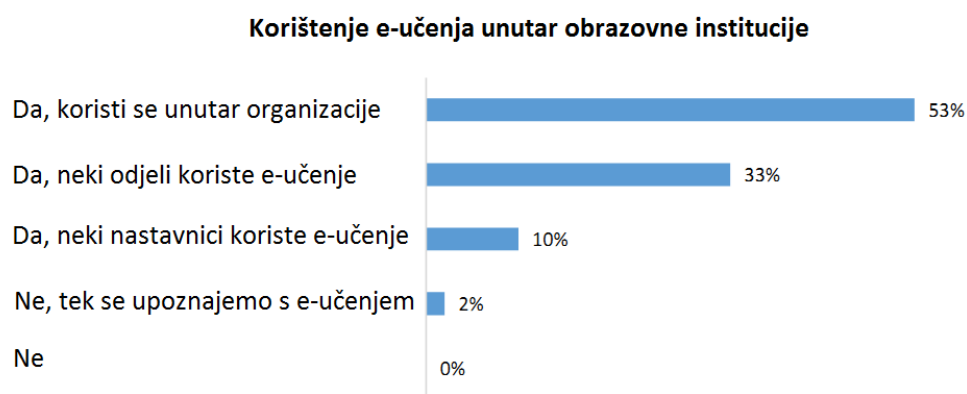
Vrsta visoko obrazovne institucije	Broj institucija	% u uzorku
Sveobuhvatna (Opća) sveučilišta	159	64
Specijalizirana sveučilišta (škole za obrazovanje nastavnika, medicinske, glazbene, poljoprivredne, jezične visoke škole, istraživački instituti i sl)	38	15
Veleučilišta (znanstvena ili stručno obrazovna institucija koja ne omogućuje doktorske studije)	21	9
Tehnička sveučilišta	26	10
Pučka otvorena učilišta	5	2
Ukupno	249	100%

Iz tablice 9. je jasno kako su u EU **Opća sveučilišta** najrasprostranjenija (64% iz uzorka) u odnosu na specijalizirana sveučilišta (15%), te veleučilišta koja broje (9%). Uključenost državnih tijela u **promociju** i **širenje** novijih trendova u obrazovanju važan je aspekt obrazovnog sustava. **Promjene** se trebaju **provoditi u cjelovitosti**, te su na pitanje ima li Vaša država nacionalnu politiku za e-učenje, odgovorili prema slici 5.



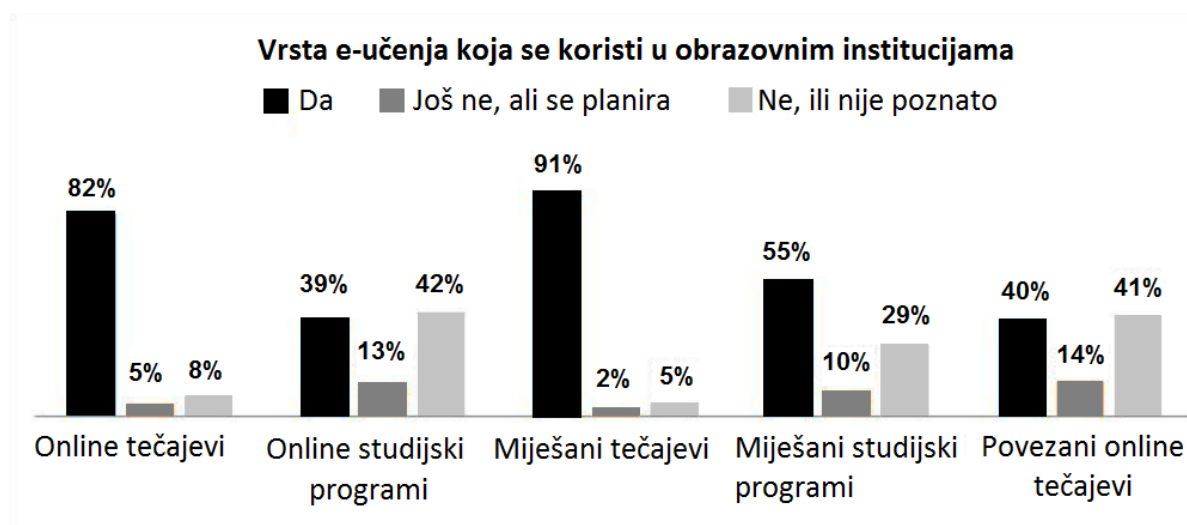
Slika 5. Nacionalna politika e-učenja (prilagođeno prema Gaebel, 2014.)

Gaebel i suradnici (2014.) navode kako na pitanje postoji li u Vašoj obrazovnoj instituciji **strategija** ili **politika** koja se odnosi na **e-učenje**, samo **49%** institucija odgovorilo je s **pozitivnim odgovorom**, gdje je 26% izjavilo kako ne posjeduju, ali se politika i strategija razvijaju. 14% ne posjeduje politiku i strategiju na razini sveučilišta, ali pojedine članice sveučilišta imaju vlastite strategije za primjenu i provođenje e-učenja. Samo je 5% ispitanika odgovorilo kako ne posjeduju ništa od navedenog. Od 245 (96%) obrazovne institucije koje su odgovarale na upitnik, njih 238 potvrdilo je kako već **primjenjuju** ili su u procesu **implementiranja strategije e-učenja** u njihovo poslovanje, te su na pitanje **koriste li e-učenje** odgovorile prema slici 6.



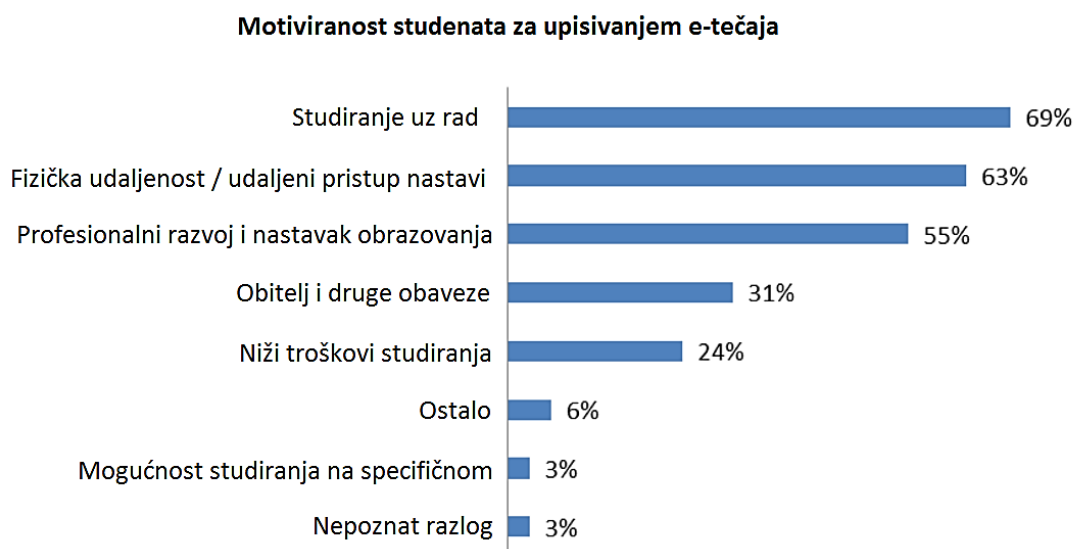
Slika 6. Koristite li e-učenje u Vašoj organizaciji (prilagođeno prema Gaebel, 2014.)

Iz slike 6. jasno je kako se e-učenje koristi unutar obrazovnih organizacija uz veliku mogućnost za širenje. Najkorišteniji tip e-učenja je miješani tečaj s 91% (eng. *blended learning courses*) dok je na *online* tečaj s 82% na drugom mjestu što se može primijetiti na slici 7.



Slika 7. Vrste e-učenja i njihova zastupljenost (prilagođeno prema Gaebel, 2014.)

Na pitanje **što motivira** studente za upisivanje *online* tečajeva, glavni razlozi su **učenje uz rad i fizička udaljenost** što je i vidljivo iz njihovih odgovora u nastavku rada na slici 8.



Slika 8. Razlozi za upisivanjem e-tečaja (prilagođeno prema Gaebel, 2014.)

Tablica 10. Nastavna područja poučavana e-učenjem (prilagođeno prema Gaebel, 2014.)

Sve discipline	22 %
Poslovanje i menadžment	37 %
Obrazovanje, osposobljavanje nastavnika	34 %
Matematika, informatika	33 %
Inženjering i tehnologija	33 %
Socijalne znanosti	27 %
Humanizam	21 %
Medicinske znanosti	19 %
Prirodne znanosti	18 %
Pravo	14 %
Arhitektura	4 %
Dizajn i umjetnost	4 %
Ostalo	14 %

Tablica 10. pokazuje područje interesa koje se podučava putem e-učenja. Jedna petina ispitanika (22%) izjavilo je kako e-učenje primjenjuju na globalnoj razini bez posebnog naglašavanja bilo koje discipline. Odgovori ostalih institucija su prikazani u ranijem prikazu, gdje se obrazovanje i disciplina poučavanja naglašava kao jedna od vodećih po pitanju visokoškolskog obrazovanja.

Williams i Goldberg (2005.) naglašavaju kako e-učenje predstavlja **postepeni evolucijski proces** gdje institucije trebaju pažljivo razraditi strategiju s naglaskom na kvaliteti. U suprotnom vrlo se lako dolazi do problematičnog stanja u kojem je poučavanje otežano te nije temeljeno na standardima dobre prakse. **Utemeljena i zvučna sveučilišta** poput Oxforda i Cambridgea, zajedeno s Harvardom i Stanfordom **nemaju pritisak** prilagodbe na nove tehnologije zbog **dugogodišnje tradicije, kulture** i uvaženog **statusa**, sada već kulturnog načina studiranja, gdje je individualan rad s mentorom i samostalno istraživanje normalno stanje svakog studenta.

Kovacova i Vackova (2015.) u svom istraživanju govore o implementaciji e-učenja u visokoškolsko obrazovanje. Navode kako se pojam e-učenja na ovoj razini razmatra zato što je studentima potrebno omogućiti slobodan i ne smetan pristup obrazovnim materijalima. Također navode kako je princip prenošenja znanja gotovo ne promijenjen. Ulaže se u suvremeniju opremu, izrađuju se novi kurikulumi, ali suština prenošenja znanja unutar učionica nije se značajno promijenila unatoč evidentno većeg broja znanstvenih činjenicama i dokumentiranog znanja. Zbog načina na koji pojedinci žive, rade i uče, bitno je osigurati **jednostavan i stalan pristup informacijama** 24/7, po što **nižoj cijeni**. E-učenje kao pojam i sustav prenošenja znanja iz navedenih razloga predstavlja racionalnu i efikasnu alternativu koja zadovoljava suvremene zahtjeve unatoč mišljenju kako nikada, u potpunosti, neće zamijeniti tradicionalan način poučavanja.

Kovacova i Vackova (2015.) govore kako je e-učenje efikasan način za povezivanje sa studentima i omogućuje dijeljenje vrijednih informacija u kraćem vremenu na većoj udaljenosti, pri čemu je povratna informacija o uspjehu trenutna.

Melánia (2015.) u svom istraživanju opisuje kako se e-učenje nije pokazalo samo kao alat za razmjenu informacija i podučavanja novih znanja, već je kod studenata zabilježen pozitivan odnos **povezivanja teorije i prakse** čime je utvrđen inovativan pristup teoretskim nastavnim materijalima i načinima pomoću kojih se stvaraju pozitivne navike i prenosi znanje. Na temelju anketnih upitnika zaključuje se kako je e-učenje stvorilo **pozitivan utisak** na studente koji su sudjelovali u istraživanju, kao i na uključene nastavnike.

Truskolaska i suradnici (2015.) opisuju stanje u Poljskoj i navode kako se e-učenje koristi na javnim i privatnim sveučilištima, kao i u privatnim poduzećima koje nisu povezane s obrazovnim sustavom. Zanimljivost je kako se **kroz sustave za e-učenje treniraju** i educiraju sami **edukatori, nastavnici** specijaliziranih znanja i **administratori** korektivnih sustava.

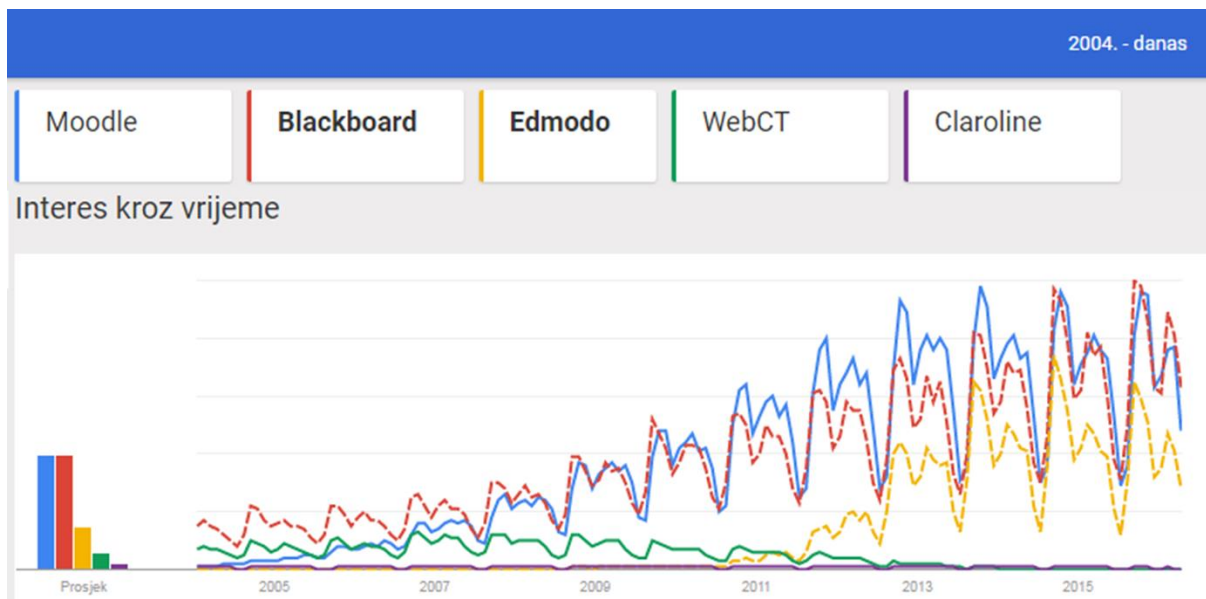
Navode kako se svako teoretsko znanje može prilagoditi i prikazati u sustavu za e-učenje, isto kao i praktična znanja gdje se **uz sustav** trebaju uklopiti i **fizičke vježbe**. Navode neke od alata pomoću kojih studenti uče kao što su ispunjavanje članaka, rješavanje testova i kvizova, povezivanje unutarnjih navoda s vanjskim poveznicama na baze znanja. Također se spominju multimedijске mogućnosti nastavnih sadržaja i **računalne igre** kao korisne mogućnosti koje bi trebalo razmotriti u fazi planiranja obrazovnih aktivnosti.

2.1.5. Moodle sustav za upravljanje učenjem u visokoškolskom obrazovanju

U ovom poglavlju opisuje se sustav za upravljanje e-učenjem pod nazivom Moodle (eng. *Modular Object-Oriented Dynamic Learning Environment*). Moodle se analizira pomoću nekoliko alata za prikaz trendova te se navode prednosti i nedostaci u visokoškolskom obrazovanju.

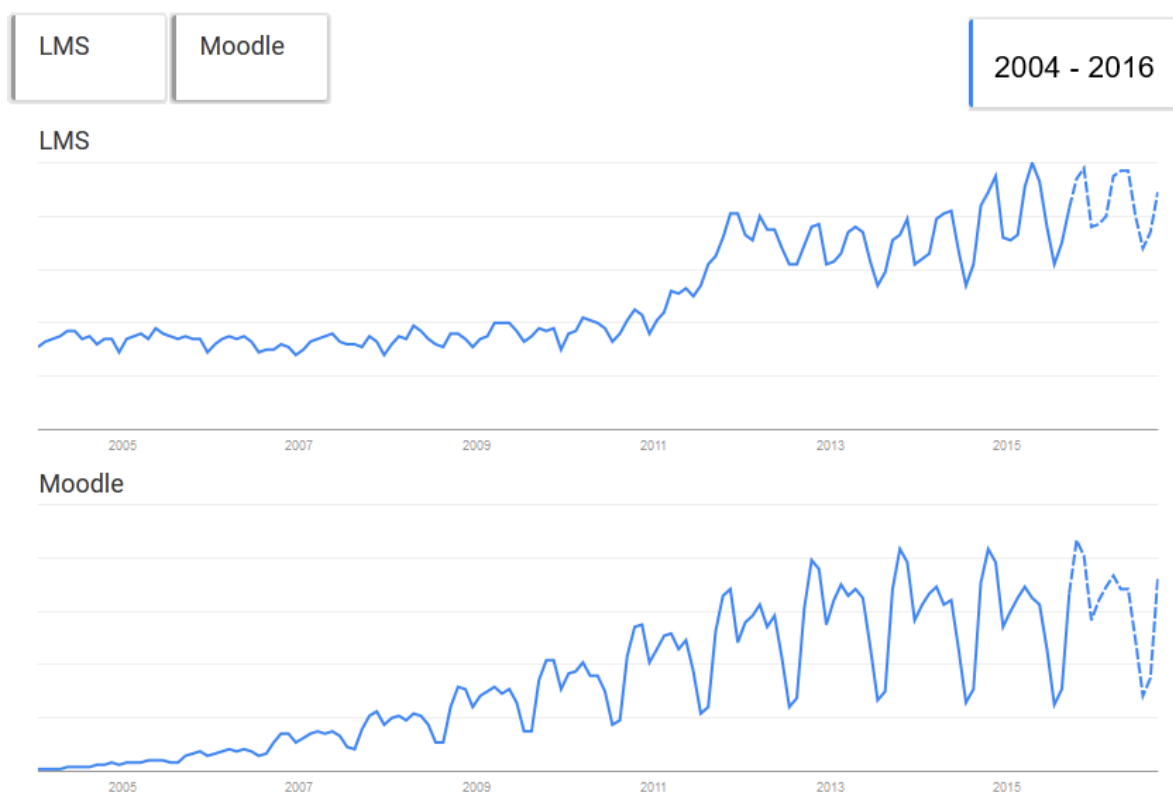
Gogan i suradnici (2015.) navode kako je Moodle sustav **otvorenog koda** (eng. *open source*) koji spada u sustave za **upravljanje učenjem**. Poulova (2015.) navodi da je Moodle 2002. godine prvi puta predstavljen kao alat koji podržava **socijalni i konstruktivistički pristup** obrazovanju. Besplatan je i vodi se unutar GNU (eng. *GNU's not unix*) licence, te pogodan za rad na **osobnom računalu, tabletu ili pametnom telefonu** dok god je osiguran pristup **Internetu**. Gogan i suradnici (2015.) naglašavaju kako je svoju popularnost među studentima i nastavnicima stekao kao alat za kreiranje **dinamičnih online web nastavnih sadržaja** gdje je fokus na **upravljanju i nadziranju** procesa **učenja**. Dizajniran je tako kako bi se nastavniku omogućila **poticajnija i efektivnija online** komunikacija, kroz **resurse i aktivnosti**, koja predstavlja temelj za učenje.

Gogan i suradnici (2015.) govore kako je Moodle platforma usmjerena poboljšanju iskustva učenja, kroz korištenje tradicionalnih metoda kao što su **vježbe i zadaci** potpomognuti informacijsko-komunikacijskom tehnologijom. Studenti mogu pristupiti nastavnim materijalima, doći u interakciju s nastavnikom i ostalim sudionicima tečaja, dobiti individualne domaće zadatke. Costa i suradnici (2012.) kroz istraživanje nad 278 studenata zaključuju kako je Moodle **stabilna platforma** koja može poslužiti i kao **repositorij nastavnih materijala**, te kako je prepoznata od strane studenata po svojoj funkcionalnosti usmjerenoj **uspješnom učenju i poučavanju**. Uz Moodle postoji veliki broj platforma koje podržavaju i omogućuju upravljanje obrazovnim sustavom među kojima su samo neki od: Blackboard, Claroline, WebCT, Alpha LMS, Link2school, CentraOne, Consensus, Web-guru, Lmswizdom, Wiziq i drugi. Međuodnos navedenih sustava prikazan je na slici 9., a trendovi na slici 10.



Slika 9. Usporedni prikaz LMS tehnologija od 2004. do 2016.

Vidljivo je kako su **Moodle**, Blackboard i Edmodo najpoznatiji pojmovi prema pretraživanju Google tražilice unutar navedenih LMS sustava. Bitno je naglasiti kako je u ovoj usporedbi Moodle jedini sustav, od najzastupljenijih u ovom grafikonu, otvorenog koda.



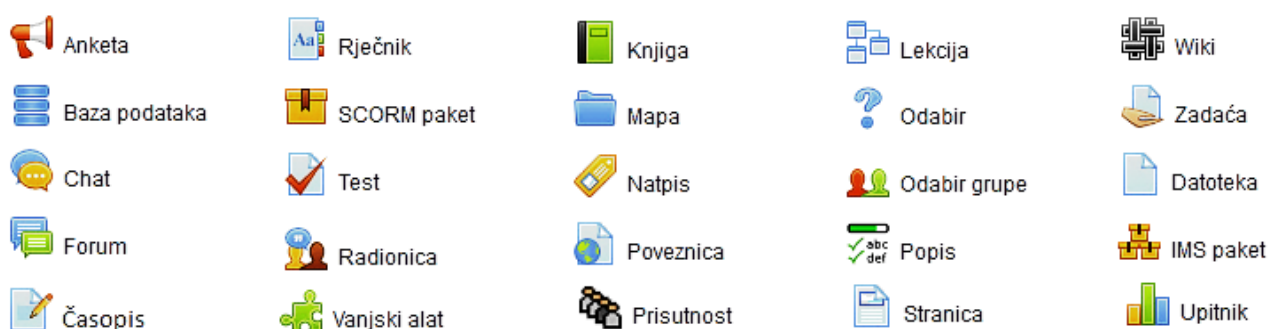
Slika 10. Prikaz trendova pomoću Google Trends alata vezanih uz pojmove LMS i Moodle od 2004. do 2016.

Kroz sliku 9. vidljivo je kako su sustavi za upravljanje e-učenjem imali **pravilan rast** i prihvaćanje na tehnološkom tržištu. Prisutno je određeno ciklično **zasićenje** koje što može biti i predmet diskusije. Razina svijesti kod korisnika stalno se povećava pogotovo po pitanju **primjene, prednosti i mogućnosti** ovog sustava u obrazovnim institucijama. Moglo bi se zaključiti kako se svakom novom verzijom Moodle sustava podiže svijest i broj novih korisnika. S obzirom na to kako je Moodle sustav otvorenog koda, institucije ga mogu **mijenjati i prilagođavati** vlastitim potrebama. Predviđanja su kako će se ovakav pozitivan trend i nastaviti, ali u češćim intervalima.

Awang (2012.) i Poulova (2015.) navode još nekoliko zanimljivosti zbog kojih bi Moodle sustav mogao biti još zastupljeniji u visokoškolskom, ali i svim ostalim obrazovnim sustavima. Korisničko sučelje Moodle sustava je intuitivno s jednostavnom navigacijom. Nastavni materijal je **strukturiran** u **manje** (dnevne, tjedne) **cjeline** unutar veće teme. Studentske aktivnosti su **automatski evidentirane** i **praćene**, te je studentima omogućena **kontrola** vlastitih obrazovnih postignuća. **Provjera znanja** podržava tradicionalne i uobičajene metode ispitivanja znanja kao što je: **dopuna**, višestruki **izbor**, **točno-netočno**, **povezivanje** pojmova, **kratki odgovor** i sl. Provjere znanja mogu se po potrebi vremenski ograničiti, isto kao i ograničiti po pitanju prvog ili višestrukog pristupa testiranju znanja. **Kooperativno učenje** s obzirom na to kako je moguća organizacija sudionika u grupe ili parove pri čemu su na raspolaganju dostupni **sinkroni** ili **asinkroni** komunikacijski alati, diskusijski forumi i sl. Jednostavno **praćenje** studentskih **aktivnosti**, korištenje nastavnih materijala, provođenje provjera znanja, te izvještavanje studenata o njihovom pojedinačnom ili grupnom uspjehu.

2.1.6. Aktivnosti i resursi prisutni u Moodle sustavu

Unutar Moodle sustava 2.7. aktivnosti i resursi su vizualno prikazani ikonama koje su zbog preglednosti navedene u zbirnom prikazu u nastavku disertacije. Ime aktivnosti i resursa se s verzijom sustava ne mijenja, dok izgled ikone, prikazan na slici 11., ovisi o verziji sustava.



Slika 11. Pregled ikona za Moodle aktivnosti i resurse

Tablica 11. Aktivnosti i resursi Moodle sustava za e-učenje (prvi dio popisa)

Naziv aktivnosti / resursa	Opis
Knjiga (eng. <i>Book</i>)	Knjiga predstavlja više stranični nastavni materijal koji je podijeljen u smislene cjeline u obliku poglavlja i potpoglavlja.
Lekcija (eng. <i>Lesson</i>)	Lekcija služi nastavnicima za kreiranje interaktivnih nastavnih sadržaja .
Rječnik (eng. <i>Glossary</i>)	Rječnik omogućuje nastavniku i polaznicima e-tečaja kreiranje i upravljanje popisom definicija i pojmova.
Baza podataka (eng. <i>Database</i>)	Baza podataka omogućuje sudionicima e-tečaja stvaranje, održavanje i pretraživanje pojmova određene tematike.
Datoteka (eng. <i>File</i>)	Datoteka omogućuje nastavniku prijenos i primjenu digitalnih sadržaja kao resursa u e-tečaju.
Mapa (eng. <i>Folder</i>)	Mapa osigurava organizaciju većeg broja datoteka na jednom virtualnom prostoru.
IMS paket (eng. <i>IMS package</i>)	IMS paket predstavlja skup datoteka koje su grupirane i pohranjene na poseban način kako bi se mogle ponovno koristiti u različitim sustavima.
SCROM paket (eng. <i>SCROM package</i>)	SCORM (eng. <i>Sharable Content Object Reference Model</i>) omogućuje prijenos i dodavanje ZIP datoteka u e-tečaj.
Stranica (eng. <i>Page</i>)	Stranica je virtualan prostor koji nastavniku osigurava stvaranje pojedinačnih web dokumenata koji će se prikazivati unutar e-tečaja i naknadno ažurirati .
Poveznica (eng. <i>Link</i>)	Poveznica kao resurs omogućuje nastavniku povezivanje e-tečaja i vanjskih web stranica.
Vanjski alat (eng. <i>External Tool</i>)	Vanjski alat kao aktivnost koju nastavnik može koristiti omogućuje povezivanje vanjskih web resursa s aktivnostima koje su ponuđene polaznicima unutar Moodle sustava.
Wiki (eng. <i>Wiki</i>)	Wiki omogućuje nastavniku uključivanje željenog broja studenata u izradu i uređivanje određenog skupa web stranica.
Popis (eng. <i>To Do list</i>)	Popis omogućuje nastavniku izradu i vizualan prikaz popisa sa zadacima .

Tablice 11. i 12., prikazuju aktivnosti i resurse koji se mogu pronaći unutar Moodle sustava koji je odabran u ovoj disertaciji za potrebe istraživačkog rada. Uz nazive aktivnosti i resursa ističe se osnovni opis za lakše razumijevanje mogućnosti sustava. Poglavlje završava grupiranim aktivnostima i resursima Moodle sustava za e-učenje koji su prikazani unutar slike 12.

Tablica 12. Aktivnosti i resursi Moodle sustava za e-učenje (drugi dio popisa)

Naziv aktivnosti / resursa	Opis
Zadatak (eng. <i>Assignment</i>)	Zadaća osigurava nastavniku zadavanje, zaprimanje, evaluiranje i davanje povratne informacije polaznicima o urađenim studentskim radovima.
Test (eng. <i>Quiz</i>)	Test omogućuje stvaranje instrumenta za provjeru znanja koji se može sastojati od različitih vrsta pitanja.
Upitnik (eng. <i>Questionnaire</i>)	Upitnik kao aktivnost unutra Moodle sustava osigurava tri anketna instrumenta na temelju kojih je omogućena procjena i poticanje učenja u <i>online</i> okruženju.
Anketa (eng. <i>Survey</i>)	Anketa je aktivnost pomoću koje je moguće prikupiti željene povratne informacije od nastavnika ili polaznika e-tečaja.
Radionica (eng. <i>Workshop</i>)	Radionica nastavniku osigurava prikupljanje, nadzor i međusobno vrednovanje studentskih radova (eng. <i>peer evaluation</i>).
Sinkrona komunikacija (eng. <i>Chat</i>)	Chat polaznicima osigurava sinkronu komunikaciju u realnom vremenu.
Asinkrona komunikacija (eng. <i>Forum</i>)	Forum u usporedbi s Chat aktivnošću, omogućuje polaznicima e-tečaja asinkron način komunikacije .
Časopis (eng. <i>Journal</i>)	Časopis ili dnevnik omogućuje polaznicima izražavanje mišljenja o temi koju nastavnik definira.
Prisutnost (eng. <i>Attendance</i>)	Prisutnost omogućuje nastavniku evidenciju dolazaka na fizičko predavanje ili vježbe, a studenti mogu jedino pregledati broj svojih dolazaka i izostanaka.
Odabir (eng. <i>Choice</i>)	Odabir je aktivnost koja nastavniku osigurava postavljanje pitanja i određivanja mogućih odabira (odgovora).
Odabir grupe (eng. <i>Group choice</i>)	Aktivnost za odabir grupe omogućuje studentima biranje i direktni upis u grupe koje je nastavnik postavio na razini e-tečaja.
Natpis (eng. <i>Label</i>)	Natpis nudi umetanje teksta i slika u poveznice aktivnosti i resursa na stranici e-tečaja.

Knjiga: Knjiga predstavlja **višestраниčni** nastavni materijal koji je podijeljen u smislene cjeline u obliku poglavlja i potpoglavlja. Knjige se temelje na tekstualnom zapisu ali mogu biti upotpunjene pomoću multimedijских sadržaja u obliku digitalnih datoteka (slika, zvuk, animacija i video). Koriste se prilikom prikaza **duljih informacijskih resursa** koji se mogu podijeliti u kraća cjeline ili poglavlja. Knjiga se može koristiti za:

- Prikaz **opsežnijih** nastavnih materijala.
- **Izradu** udžbenika.

Lekcija: Lekcija služi nastavnicima za kreiranje **interaktivnih nastavnih sadržaja**. Pomoću lekcije, nastavnik može stvoriti stranicu s **linearnim** nastavnim sadržajem ili izraditi aktivnost koja studentu pruža **nekoliko alternativa** po pitanju **odabira** i **opcija** nastavnih sadržaja. Kroz lekcije nastavnici mogu povećati **interakciju** studenata **sa sadržajem** pomoću raznovrsnih pitanja (višestruki odgovori, pitanja s uparivanjem i sl.). Polaznici e-tečaja mogu **napredovati** u lekciji dalje ili biti **vraćeni na prethodnu** stranicu ovisno o danim odgovorima. Postoji mogućnost i usmjeravanja na neko od grananja sadržaja. Lekcija može biti ocijenjena i može se koristiti za:

- **Samostalno učenje**.
- Scenarije koji obuhvaćaju **simulacije** ili **vježbe iz odlučivanja**.

Rječnik: Rječnik omogućuje nastavniku i polaznicima e-tečaja **kreiranje** i **upravljanje** popisom definicija i pojmova. Studentima se uz dodavanje pojmova može omogućiti i dodavanje priloga. Ako postoje slike u sustavu za pojedini pojam, bit će automatski prikazane u sklopu pojma. **Pretraživanje** ili **pregledavanje** pojmova moguće je korištenjem abecednog kazala, odabirom kategorija, datuma objave ili autora. Ovisno o postavkama, pojmovi se mogu automatski ažurirati ili se treba pričekati odobrenje nastavnika. Pojmovi se mogu automatski povezati s tekstualnim nastavnim sadržajem e-tečaja. Komentiranje pojmova može biti dozvoljeno. Uneseni pojmovi **mogu ocijenjeni** od strane nastavnika i drugih polaznika e-tečaja. Ocjene se mogu zbrajati i utjecati na završnu ocjenu tečaja. Rječnik se može koristiti za:

- **Suradničku bazu** ključnih pojmova.
- Mjesto **za dijeljenje** digitalnih poveznica, video snimki, slika ili zvučnih datoteka.
- Mjesto **za pohranu** materijala za ponavljanje i učenje.

Baza podataka: Baza podataka omogućuje sudionicima e-tečaja **stvaranje, održavanje i pretraživanje** pojmova određene tematike. Polaznici imaju slobodu po pitanju oblika i količine unosa prilikom unosa novih zapisa. Sustav omogućuje korištenje slika, datoteka, URL adresa, brojčanih i tekstualnih podataka i dr. Struktura baze je određena od strane nastavnika ili administratora sustava. **Vizualni prikaz** informacija može biti mijenjan ovisno o predlošku koji se koristi. Ista baza podataka može biti korištena između više e-tečaja, gdje se zapisi mogu uvoziti i izvoziti iz baze prema potrebi nastavnika. Postoji mogućnost **automatskog povezivanja** unesenih pojmova. Ako je navedeno aktivirano, prepoznati identični pojmovi bit će pretvoreni u poveznice na zapise u bazi. Nastavnik može dopustiti **komentiranje zapisa**. Nastavnik i polaznici e-tečaja međusobno, mogu ocjenjivati unose u bazi te tako utjecati na završnu ocjenu polaznika e-tečaja. Baza podataka može se koristiti za:

- **Suradničku zbirku** web poveznica, popisa knjiga, referentnih izvora i sl.
- **Prikaz materijala** koje su stvorili studenti: fotografije, galerije, članci i sl.

Datoteka: Datoteka omogućuje nastavniku prijenos i primjenu digitalnih sadržaja kao resursa u e-tečaju. Akcija nakon odabira sadržaja datoteke može se postaviti na dva načina. Datoteka se može prikazivati **u sklopu sučelja** sustava ili se u suprotnom, studentima daje mogućnost **lokalne pohrane** na računalo. Nužno je istaknuti kako studenti na lokalnom računalu trebaju imati instaliran program kojim će moći pregledavati sadržaj datoteke koje su preuzeli. Datoteke se mogu koristiti za:

- **Dijeljenje** sadržaja s predavanja i studentskih zadataka.
- **Dijeljenje** datoteka s člancima / publikacijama s literaturom.

Mapa: Mapa osigurava organizaciju **većeg broja datoteka** u na jednom virtualnom prostoru. Koristi mape rezultiraju **smanjivanjem zakrčenost** naslovnice e-tečaja do koje može doći uslijed većeg broja poveznica prema nastavnim materijalima. Jedan tip mape može biti i **ZIP arhiva** koja i **komprimira** odabrane datoteke. Prije dijeljenja ZIP arhive s polaznicima korektno je prvo osigurati otpakiranje. Druga mogućnost je kreiranje prazne mape na poslužitelju kojemu polaznici imaju pristup te je prema potrebi dopuniti sa željenim datotekama. Mapa se može koristiti za:

- **Organizaciju i prikaz** datoteka koje sadrže članke i knjige.
- **Prikaz većeg broja datoteka** slične tematike.

IMS paket: IMS paket predstavlja **skup datoteka** koje su grupirane i pohranjene na poseban način kako bi se mogle ponovno koristiti u različitim sustavima. Modul osigurava **prijenos** paketa na server u obliku komprimirane ZIP datoteke. Omogućeno je i **dodavanje** sadržaja kao resurs u e-tečaj. **Sadržaj** se može pokazivati **na nekoliko** stranica uz pomoć kretanja i navigacije među stranicama. Sudionicima e-tečaja su na raspolaganju nekoliko opcija za prikaz sadržaja poput opcije za prikaz sadržaja u novom prozoru, s navigacijskim izbornikom, gumbima, itd. IMS paket može se koristiti za prikaz **multimedijskog sadržaja i animacija**.

SCORM paket: **Skup datoteka** usmjerene učenju unutra Moodle sustava naziva se SCORM paket. SCORM (eng. *Sharable Content Object Reference Model*) omogućuje **prijenos** i **dodavanje** ZIP datoteka u e-tečaj. SCORM omogućuje sastavljanje pitanja za provjeru studentovog znanja. Ocjene se bilježe u sustav, te mogu utjecati na završnu ocjenu tečaja. SCORM aktivnosti mogu se koristiti:

- Za **prikaz** multimedijskog sadržaja i animacija.
- Kao alat za **provjeru znanja**.

Stranica: Stranica je virtualan prostor koji nastavniku osigurava stvaranje **pojedinačnih web dokumenata** koji se **prikazivati** unutar e-tečaja i naknadno **ažurirati**. Stranica može sadržavati sve multimedijalne elemente poput teksta, slike, zvuka, animacije, videa, pa čak i web poveznice ili ugrađeni kôd. U odnosu na modul "Datoteka", stranica kao resurs ima znatnu prednost po pitanju jednostavnosti pristupa željenoj informaciji. Unutar resursa "Stranice" osiguravan je jednostavan pristup informacijama i sadržaju posebno ako je potrebno do istih doći pomoću mobilnih uređaja. Sadržaj stranice je jednostavno **ažurirati** i **mijenjati**. U slučaju duljih tekstova i veće količine sadržaja, nastavnicima se sugerira korištenje resurs "Knjiga" umjesto "Stranica". Stranica se može koristiti za:

- **Popis** literature s **poveznicama** na knjižnični katalog ili *online* dostupne članke.
- Za **umetanje** video i zvučnih datoteka **odjednom**, uključujući i popratni tekst.

Poveznica: Poveznica kao resurs omogućuje nastavniku povezivanje e-tečaja i vanjskih web stranica. Bilo koji digitalni **objekt, datoteka** ili **stranica** koji su dostupni putem Interneta mogu biti uključeni u e-tečaj putem poveznice. Akronim *URL* (eng. *Uniform Resource Locator*) predstavlja usklađeni lokator sadržaja. Ako je potrebno postavljanje URL, to je moguće kroz **izravno** kopiranje i lijepljenje adrese unutar sadržaja e-tečaja. Druga mogućnost je korištenje **repozitorija** (npr. Flickr, YouTube ili Wikimedia) unutar dijaloških okvira. Količina ponuđenih repozitorija ovisi o odluci administratora na razini obrazovne ustanove.

Postoji više načina za prikaz poveznice kao što je **ugradnja** (eng. *embed*) poveznice u e-tečaj ili otvaranje poveznice u **novom odvojenom prozoru**. Uz klasičnu poveznicu omogućeno je slanje pojedinih attribute kao što je korisničko ime polaznika. Poveznice se mogu **uključiti** u bilo koji **dodatni resurs** ili **aktivnost** kroz izbornik i opcije uređivača teksta.

Vanjski alat: Vanjski alat kao aktivnost koju nastavnik može koristiti omogućuje povezivanje vanjskih web **resursa** s aktivnostima koje su ponuđene polaznicima unutar Moodle sustava. Za primjenu ove aktivnosti, nužno je osigurati interoperabilne obrazovne alate, LTI (eng. *Learning Tools Interoperability*). Nastavnik može kreirati vanjski alat ili koristiti alat podešen od strane administratora. Vanjski alati u odnosu od URL resurs, razlikuju se u sljedećem:

- Imaju **pristup informacijama** o korisniku koji je pokrenuo alat, poput institucije, e-tečaja i naziva.
- Podržavaju **čitanje, nadogradnju i brisanje** ocjena koje su povezane s ovom instancom aktivnosti.
- Stvaraju **sigurnu vezu** za komunikaciju između sjedišta i pružatelja alata.

Wiki: Wiki omogućuje nastavniku uključivanje željenog broja studenata u **izradu** i **uređivanje** određenog skupa web stranica. Wiki se može koristiti u **kolaboracijskom okruženju**. Polaznici e-tečaja imaju mogućnost **unositi, uređivati** i **ažurirati** kako nove tako i postojeće zapise. Okruženje može biti i organizirano i kao **individualan rada**, pri čemu svaki polaznik e-tečaja ima svoj vlastiti wiki i ovlasti samo nad svojim dijelom. Ranije verzije tj. prethodne inačice svake stranice su pohranjene. Aktivnost svakog sudionika je vidljiva kroz pregled aktivnosti u ranijim verzijama. Wiki se može koristiti za:

- **Vodenje** bilješka ili skripte.
- **Planiranje** i **provođenje** grupnih aktivnosti.
- **Dnevnike rada** ili popis revizija u individualnom radu.

Popis: Popis omogućuje nastavniku izradu i vizualan prikaz **popisa sa zadacima** (eng. *To Do list*). Popis se može pozicionirati na glavnu stranicu e-tečaja čime se polaznicima na jasan način prikazuje što ih sve očekuje unutar e-tečaja. Vide točan broj aktivnosti koje trebaju savladati, nazive i tip aktivnosti te okvirni kraj zadanih obveza.

Zadaća: Zadaća osigurava nastavniku **zadavanje, zaprimanje, evaluiranje** i davanje **povratne informacije** polaznicima o urađenim studentskim radovima. Polaznici mogu predati sadržaj u jednom od sljedećih digitalnih formata, poput tekstualnih datoteka, tablica ili slika. Uz navedeno, tekst se može unijeti izravno u definirano polje za unos koristeći *online* obrazac. Zadaća može poslužiti i kao **podsjtnik** polaznicima e-tečaja na seminare i zadatke koji se ne predaju *online*, već u **fizičkom okruženju** ili **papirnatom obliku**. Navedene studentske aktivnosti i dalje se mogu ocijeniti kao da su **aktivnosti sustava**, te se takva ocjena bilježi u sustavu. Polaznici e-tečaja zadaću predaju kao pojedinci ili kao članovi grupe. Predana zadaća može se ocjenjivati pomoću brojčane ili prilagođene skale. Alternativa bi bila korištenje naprednih načina ocjenjivanja uz prethodno postavljanje uvjeta i kriterija. Završne ocjene bilježe se u sustavu.

Test: Alat omogućuje stvaranje instrumenta za provjeru znanja koji se može sastojati od različitih vrsta pitanja. Neki tipovi navode se u nastavku: pitanja s **višestrukim** odgovorima, **točno/netočno** pitanja, pitanja **uparivanja**, **numeričkih pitanja** i drugih vrsta. Ako je potrebno, nastavnik može osigurati višestruki pristup rješavanju i predaju testa. Pitanja i odgovori lako mogu biti generirani pomoću metode slučajnog odabira iz baze pitanja. Svaki studentov pristup pitanjima **automatski se ocjenjuje**. Povratna informacija je trenutna po završetku provjere znanja. Nastavnik može odlučiti žele li polaznicima prikazati i točne odgovore, ako je odgovor studenata bio pogrešan, ili samo označiti točne odgovore. Testovi se mogu koristiti za:

- **Pisanu provjeru** znanja.
- **Samo procjenu** studenata.

Upitnik: Upitnik kao aktivnost unutra Moodle sustava osigurava tri anketna instrumenta na temelju kojih je omogućena **procjena** i **poticanje** učenja u *online* okruženju. Nastavnik ovakvu aktivnost može koristiti za prikupljanje podataka i povratnih informacija o svojim predavanjima i načinu vlastitog poučavanja. Pitanja koja nastavnik ima na raspolaganju su unaprijed predefinirana. Ako se želi kreirati vlastiti set upitnika, trebalo bi se razmotriti korištenje ankete.

Anketa: Anketa je aktivnost pomoću koje je moguće prikupiti željene povratne informacije od nastavnika ili polaznika e-tečaja. Omogućuje korištenje različitih formata pitanja poput **višestrukih odabira**, **da/ne** pitanja ili unosa **teksta**. Ako je potrebno, može biti anonimna. Rezultati prikupljenih odgovora može vidjeti samo anketar, pojedinac koji je bio anketiran ili odabrana grupa sudionika (ovisno o postavkama).

Anketa može biti korištena za:

- **Evaluaciju** kolegija.
- **Pomoć** polaznicima pri upisu na nove kolegije, događanja i sl.
- Prikupljanje **mišljenja**.
- **Prijavu incidenata** (eng. *mobbing, bullying*).

Radionica: Radionica nastavniku osigurava **prikupljanje, nadzor i međusobno vrednovanje** studentskih radova (eng. *peer evaluation*). Studenti svoje odgovore ili rezultat rada mogu predati kao digitalni sadržaj, u obliku **tekstualnih datoteka, tablica ili slika**. Omogućeno je **unošenje teksta** izravno u polje namijenjeno za unos koristeći *online* obrazac.

Predani studentski radovi procjenjuju se korištenjem posebnih više-kriterijskih obrazaca koje definira nastavnik. Proces **međusobne studentske procjene**, upoznavanje s obrascem, te sama priprema aktivnosti za procjenu može se vježbati unaprijed pomoću primjera koje zadaje nastavnik (što uključuje i primjer ocjenjivanja). Polaznicima je dana mogućnost procjene jednog ili više rada njihovih kolega. Predavanje radova isto kao i njihova procjena može biti **anonimna** ako je tako određeno unutar postavka aktivnosti. Studenti bi za ovu aktivnost trebali dobiti dvije ocjene i to jednu za rad koji su **predali**, a drugu za **procjenu** radova svojih kolega. Obje ocjene bilježe se odvojeno u sustavu.

Chat: Chat polaznicima osigurava **sinkronu komunikaciju** u realnom vremenu. Korištenje ove aktivnosti može biti slobodna ovisno o potrebama studenata, može se ponavljati u isto vrijeme svakog dana ili svakog tjedna. **Zapisi** unutar aktivnosti se **pohranjuju**. Zapisi mogu biti dostupni svima ili samo nastavniku. Chat je posebno koristan i može se koristiti za:

- **Razmjenu iskustava** s korisnicima istog e-tečaja, koji su fizički na drugoj fizičkoj.
- **Sinkroni način komunikacije** s nastavnikom ili ostalim sudionicima.
- **Webinar / konferencija** s pozvanim predavačem koji je na drugoj lokaciji.
- **Sesije** gdje nastavnici ili drugi studenti postavljaju probna pitanja **za provjeru znanja**.

Forum: Forum u usporedbi s Chat aktivnošću, omogućuje polaznicima e-tečaja **asinkron način komunikacije**. Komunikacija unutar foruma može trajati dulje vrijeme. Postoji nekoliko mogućnosti za forum koje nastavnik ili administrator može postaviti u e-tečaj. Standardni forum je aktivnost unutar e-tečaja gdje bilo tko od studenata može pokrenuti raspravu u bilo koje vrijeme. Moguće je postaviti ograničenja gdje svaki student može pokrenuti samo jednu raspravu. Postoji mogućnost odabira foruma s pitanjima i odgovorima gdje polaznici odgovaraju na pitanja te potom imaju uvid u tuđe odgovore.

Nastavnik ili administrator može osigurati **dodavanje digitalnog sadržaja** u obliku datoteka, gdje se privitak vidi kao dio poruke na forumu.

Polaznici e-tečaja mogu se **pretplatiti** na forum kako bi dobivali informacije o novim porukama čim su objavljene od strane nastavnika ili drugih sudionika. Nastavnik ili administrator može odabrati načine pretplate: **opcionalno**, obvezno (svi) ili **automatski**. Pretplata na forum se isto tako može ukinuti u potpunosti. Broj poruka koje polaznici mogu poslati u određenom periodu može se ograničiti, čime se osigurava ravnomjerna zastupljenost odgovora u raspravi. **Poruke** na forumu **mogu ocjenjivati** i nastavnici i drugi polaznici e-tečaja. Ocjene se mogu zbrajati i utjecati na završnu ocjenu tečaja. Primjene foruma:

- Prostor za **druženje** i međusobno **upoznavanje** studenata.
- **Oglasna ploča** za najave i obavijesti na razini e-tečaja.
- **Rasprava** o sadržajima /materijalima na e-tečaju.
- **Nastavak rasprave** započete na predavanju.

Časopis: Časopis ili dnevnik omogućuje polaznicima **izražavanje mišljenja** o temi koju nastavnik definira. Izjave polaznika mogu se koristiti kao **povratna informacija** nastavniku.

Prisutnost: Prisutnost omogućuje nastavniku **evidenciju dolazaka** na fizičko predavanje ili vježbe, a studenti mogu jedino pregledati broj svojih dolazaka i izostanaka. Nastavnik može stvoriti višestruke sesije i označiti stanje dolaska studenta kao "Prisutan", "Odsutan", "Kasnio" ili "Ispričan" ili zadati svoje prilagođene nazive. Nakon zapisivanja dolazaka, nastavnik ima mogućnost **pregleda** i **izvoza izvještaja** za cijelu grupu studenata ili pojedince.

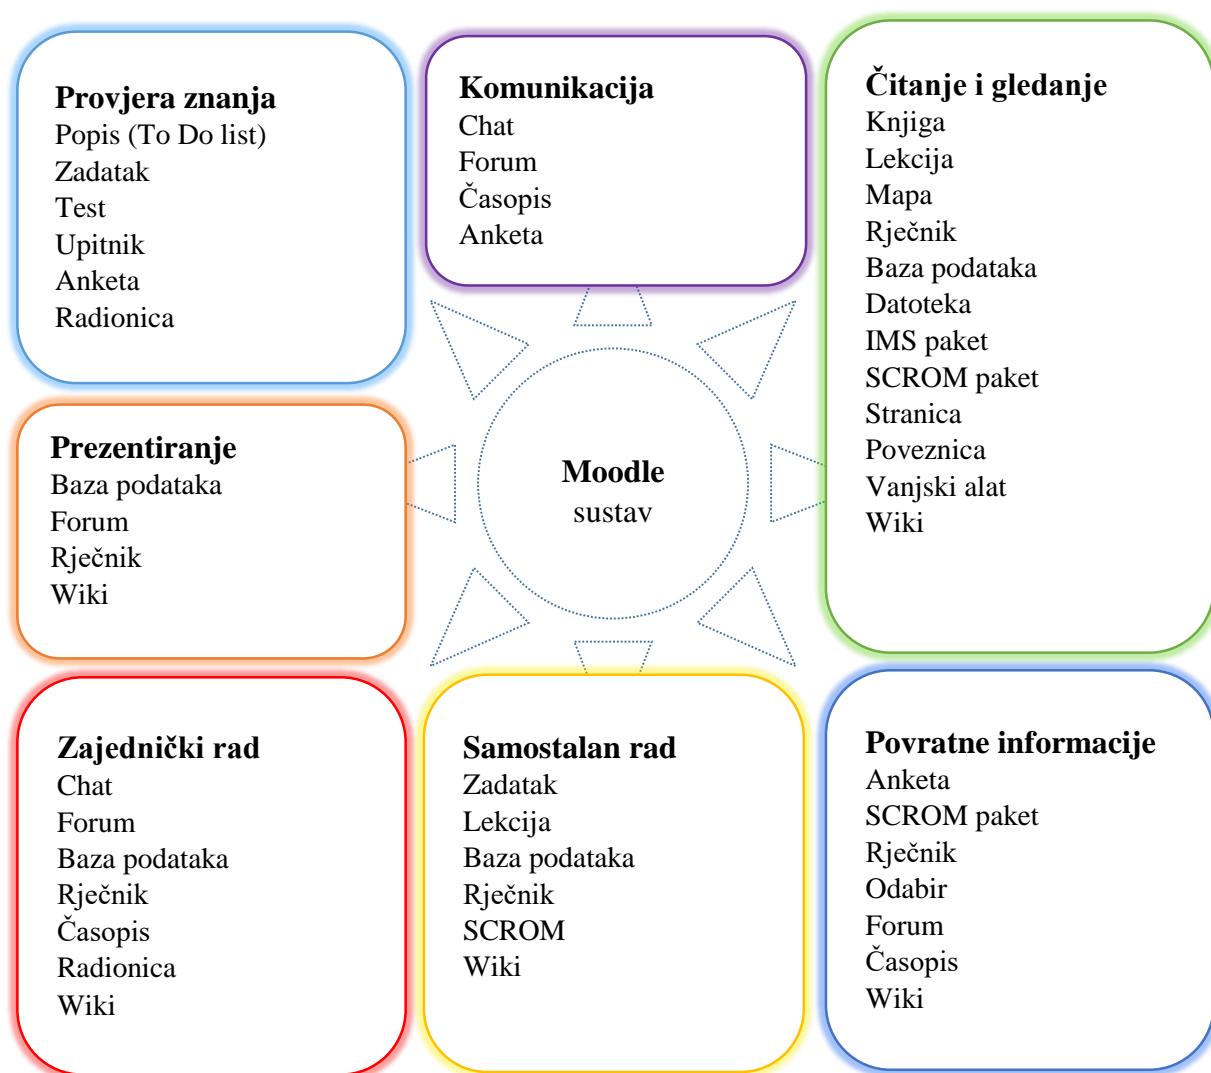
Odabir: Odabir je aktivnost koja nastavniku osigurava postavljanje pitanja i određivanja mogućih odabira (odgovora). Ovisno o postavkama sustava, odabir koji su studenti ponudili, može biti objavljen odmah ili nakon određenog vremena. Ako je tako postavljeno, dostupnost odgovora može biti omogućeno samo nastavniku. Rezultati mogu biti i javni, te objavljeni sa studentskim imenima ili anonimno. Odabir se može koristiti:

- Kod **odabira grupe, teme** seminarskog rada i sličnog (između više ponuđenih).
- Za brzu i jednostavnu **provjeru shvaćenog** predavanja.

Odabir grupe: Aktivnost za odabir grupe omogućuje studentima biranje i **direktni upis** u grupe koje je nastavnik postavio na razini e-tečaja. Nastavnik bira naziv grupe, termine i maksimalan broj polaznika. Ovisno o postavkama, student jednom odabranu grupu više ne može mijenjati.

Natpis: Natpis ističe **umetanje** teksta i slika u poveznice **aktivnosti** i **resursa** na stranici e-tečaja. Natpisi osiguravaju **jednostavniju organizaciju** i **pregledniji izgled** e-tečaja. Natpisi se mogu koristiti za:

- **Dijeljenje** popisa aktivnosti ili resursa korištenjem **podnaslova** ili **grafičkih elemenata**.
- **Prikaz** ugrađenih (eng. *embed*) zvučnih ili video datoteka.
- **Dodavanje** kraćih opisa sekcija / dijelova e-tečaja.



Slika 12. Grupirane aktivnosti i resursi Moodle sustava za e-učenje (pregled sačinio autor disertacije)

2.1.7. Budući razvoj e-učenja

Kuleto i Dedić (2014.) navode u svojoj knjizi kako budući trendovi u obrazovanju ovise o karakteristikama **učenika** i **nastavnika**, te **akademske** i **tehnološke** faktorima.

S **aspekta učenika**, prema Kuleto i Dedić (2014.), vidljivo je kako:

1. Tendencija ljudi koji stječu **visokoškolsku diplomu** je u **porastu**. Predviđanja su kako će u sljedećih deset godina broj studenata koji upisuju fakultete i druge visokoškolske ustanove biti veći za **16%**. Problem koji će se javljati je vezan za **fizički kapacitet** učilišta, gdje je jedno od mogućih rješenja prelazak, **djelomično** ili u **potpunosti** na **e-obrazovanje**.
2. Sve veći broj studenata traži **fleksibilnost** obrazovnih programa koji su postavljeni u skladu s **individualnim potrebama**, svakodnevnim životnim **navikama** i **situacijama**. Obrazovne institucije se prilagođavaju tako da se nude **specijalizirane** studijske programe i omoguće **mobilitet studenata** prilikom studiranja. Predviđa se kako će se konkurentnost obrazovnih institucija povećati, te da će opstati ona koja ulože znatan napor u **marketing** i **promociju**, kontroliranu **kvalitetu** i **efikasnost** korištenja novih tehnoloških rješenja.
3. Na trendove u visokoškolskom obrazovanju utječe i promjena profila studenata. Studenti koji pohađaju *online* obrazovne programe preferiraju stil učenja koji se temelji na rješavanju **praktičnih problema** i učenje temelje na principu **pokušaja** i **pogreška**. Unutar obrazovnog procesa studenti očekuju dobivanje brze povratne informacije i naputke kako doći do cilja u interakciji s virtualnim nastavnikom. S obzirom na to kako se ovdje govori o "**Generaciji Z**", obrazovni sustav će se trebati mijenjati svake godine u skladu s mogućnostima obrazovne institucije (**Ramar** i **Owens**, 2016.).

S **aspekta nastavnika**, prema Kuleto i Dedić (2014.), vidljivo je kako:

1. Uloga nastavnika zahtjeva **posjedovanje** i razvijanje **specijaliziranih znanja** iz određenog interesnog područja. Nastavnici koji koriste tehnologiju za e-obrazovanje moraju biti dobro **organizirani**, **planirati** unaprijed i biti uvijek **dostupni** za komunikaciju sa studentima. Prioritet je **dostupnost** i **pravovremena komunikacija** s obzirom na to kako je nastupila **fizička udaljenost** između nastavnika i studenta.
2. Potreba za osiguravanjem **pravilne obuke**, **razvoja** i **podrške** nastavnicima je sve izraženija. Tradicionalni nastavnici koji pokušavaju primjenjivati konvencionalne metode poučavanja često završavaju bezuspješno.

Glavni razlog je vrlo često **nedovoljno znanja** nastavnika za korištenjem suvremenih tehnoloških rješenja u nastavi. Nerijetko se uočava slučaj u kojem student posjeduje više znanja o specifičnoj temi od nastavnika koji temu prezentira. Iz navedenih razloga potrebno je osigurati pravilnu nastavničku **podršku** i **izobrazbu**, kako bi povezivanja tehnoloških mogućnosti i obrazovanog sustava bio uspješan. Navedeno se smatra jednim od **kritičnih strateških pitanja** u domeni e-obrazovanja.

3. Značajan faktor koji utječe na budućnost e-obrazovanja, s aspekta nastavnog osoblja, je **otpor** koji se javlja s novim metodama, principima, tehnološkim rješenjima. Brojne pojave utječu na pojavu otpora, ali glavni utjecaj ima **politika nagrađivanja** koju primjenjuje obrazovna institucija. Čest uzrok otpora IT promjenama jest mišljenje kako nastavnik **mora uložiti** dodatno vrijeme i **napor** u svladavanje, često ne željene, promjene. **Potica** za cjeloživotno obrazovanje nastavnog osoblja moguće je uz adekvatno rješenje navedenog problema.
4. Osjećaj **isključenosti** i **usamljenosti** može utjecati na nastavnikov stav o napredovanju i uključivanju u suvremene obrazovne aktivnosti. Činjenica je kako nastavnici koji rade u virtualnom okruženju nemaju kontakt sa studentima čime se navedeni problem može pojaviti.

S **akademskega aspekta**, prema Kuleto i Dedić (2014.), vidljivo je kako:

1. Količina raspoloživog **znanja** i **informacija** raste **eksponencijalno**. U ranijoj prošlosti **količina** se raspoloživih informacija **udvostručila** svakih **deset godina**. Danas taj ciklus traje **četiri godine**, s tendencijom **ubrzanja** i dodatnog skraćivanja vremena. Ova okolnost izravno utječe na **buduće trendove** u sveukupnom obrazovanju.
2. Institucijsko okruženje u kojem se odvija proces visokoškolskog obrazovanja se mijenja. Tendencije koje se uočavaju su pojava **profitnih organizacija** koje se bave obrazovanjem. Istraživanja pokazuju kako je trenutno **4-5%** studenata koji aktivno pohađaju tradicionalno visokoškolsko obrazovanje koje organiziraju **privatne profitne** institucije. Zanimljivo je i to kako je broj studenata koji se obrazuju putem **privatnih online tečaja 33%**. Ono što se naslućuje jest pitanje: "Gdje je mjesto u obrazovanju budućnosti za obrazovne institucije koje su usluge obrazovanja pružale na tradicionalan način?"
3. S naglaskom na obrazovni proces koji je orijentiran studentu, dolazi se do transformacije modela u kojem student dolazi do informacija pri čemu su u prvom planu **konstruktivističke** i **metakognitivne** metode stjecanje novih informacija i znanja.

Studenti kroz komunikaciju koja se temelji na korištenju informacijsko komunikacijske tehnologije preuzimaju sve **veću odgovornost** za svoje **učenje**.

4. U visokoškolskom obrazovanju sve je veća tendencija **iznajmljivanja usluga** vanjskih suradnika i usko **specijaliziranih partnera**. Tradicionalno, sveučilišta su bila **samostalne institucije**. Paralelno s navedenim, institucije koje su uključene u e-obrazovanje su **kooperativnije** i sklone su **strateškim partnerstvima** s drugim obrazovnim institucijama. Istraživanja pokazuju kako tradicionalne institucije postaju sve više nalik na institucije kojima je primarna djelatnost e-obrazovanje, tako da sve češće sklapaju strateška partnerstva s drugim sveučilištima, fakultetima i privatnim kompanijama s ciljem **dijeljenja tehnologije i stručnosti** zbog kreiranja distribucije **kvalitetnih** nastavnih sadržaja.

S **tehnološkog aspekta**, prema Kuleto i Dedić (2014.), vidljivo je kako:

1. Tehnologija i tehnološke inovacije **javno su prihvaćene** i **sveprisutne** te uvelike utječu na **promjene** u obrazovnom sustavu i budući razvoj obrazovnih programa. Računalna snaga se svake godine **povećava**, a uređaji bazirani na procesorskoj obradi podataka i informacija postaju sve **jeftiniji**. Paralelno s navedenim vidljivo je kako i komunikacijska tehnologija doživljava pozitivne promjene po pitanju **širokopojsnog Interneta** čime bi se mogao riješiti jedan od značajnijih problema koji se pojavljuje u tradicionalnom obrazovnom sustavu. Govori se o komunikaciji **licem u lice**. **Interaktivna televizija i video konferencije** efikasne su metode za rješavanje ovog problema i izjednačavanje e-obrazovanja i tradicionalne nastave.
2. Porast broja korisnika koji koristi Internet usluge značajna je pretpostavka razvoja e-obrazovanja. Budući da je Internet medij koji omogućuje **razmjenu** podataka, informacija, nastavnih materijala i znanja na bilo kojoj lokaciji, logično je pretpostaviti kako **broj korisnika** direktno **utječe** i na oblikovanje **trendova** e-obrazovanja.
3. Paralelno s porastom broja korisnika Internet usluga, raste i informatička pismenost, kao jedan od glavnih preduvjeta uspješnog sudjelovanja u *online* nastavi.

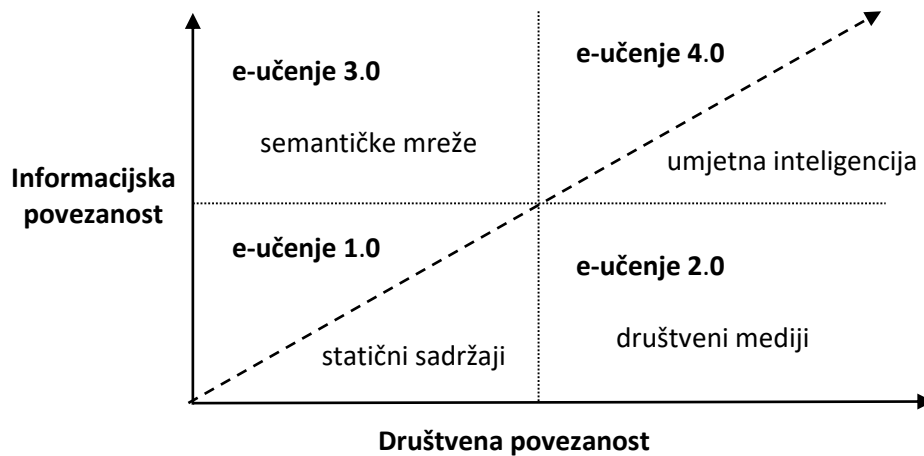
Ostali faktori koji utječu na budućnost e-obrazovanja, prema Kuleto i Dedić (2014.):

1. **Cjeloživotno obrazovanje.** Evidentno je kako pojedinac tijekom svoje radne karijere promijeni posao **barem jednom** u manje od deset godina. 40% zaposlenih **mijenja posao svake godine**, a s time se i **prekvalificiraju** za nova radna mjesta kako bi postali podobni i konkurentni na tržištu rada. E-obrazovanje može efikasno potpomoći povećanu potrebu za cjeloživotnim obrazovanjem i tu se očituje jedna od **snaga** u odnosu na tradicionalno obrazovanje.
2. **Financijski aspekt e-obrazovanja.** E-obrazovanje je jednim dijelom nastalo kao rješenje za **ograničene resurse** obrazovnih institucija, na prvom mjestu fizičke kapacitete. Uz fizičke kapacitete, uključeni su troškovi obrade i kreiranja, nastavnih materijala, te transport obrazovnog osoblja (nastavnika, studenata, administrativnih stručnjaka). Adekvatno rješenje ovog pitanja moglo bi značajno utjecati na buduće trendove u e-obrazovanju.

Williams i Goldberg (2005.) govore kako se e-učenje 90-tih godina prošlog stoljeća zvalo **računalno bazirano poučavanje**. LMS sustavi pojavljuju se kao projekti bazirani na lokalnim računalnim mrežama (eng. *Local Area Network, LAN*) kako bi **podržali** i lakše **kontrolirali** razmjenu informacija i ideja u sustavu. LMS i tadašnji sustavi za učenje doživjeli su širenje WWW, svjetske računalne mreže (eng. *World Wide Web*) i kao takvi uvidjeli mogućnost **širenja izvan LANa**, gdje se nalaze i danas. Obrazovni sustavi podržani su suvremenom tehnologijom, širokopojasnim Internetom i pedagoškim vještinama koje podržavaju e-učenje kao **standard** i **suvremeni odgovor** na obrazovni sustav. Rezultat je taj kako studenti imaju veći stupanj **autonomije**. **Komunikacija, interakcija** i **razmjena** informacija među studentima je opće prihvaćeno stanje u kojem se e-učenje sagledava kao vrlo **demokratsko rješenje** u kojemu svaki student ima jednako pravo pisanog "glasa" bez mogućnosti **nadglasavanja, prekidanja** ili **požurivanja** iznošenja mišljenja.

Williams i Goldberg (2005.) navode kako istraživači i institucije posjeduju tehnologiju i vrlo detaljno dokumentirane **prednosti** i **nedostatke**, više ili manje **uspješnih**, pokušaja implementiranja e-učenja. Promjene u okruženju i načinima provođenja e-učenja vrlo su blizu trenutka kada će se temelji obrazovnog sustava trebati mijenjati u skladu s tehnološkim mogućnostima.

Kovacova i Vackova (2015.) razmatraju evoluciju e-učenja kroz četiri dimenzije prikazane u nastavku ovog rada na slici 13.



Slika 13. Evolucija e-učenja (prilagođeno prema Kovacova i Vackova, 2015.)

E-učenje 1.0 bazirano je na **statičnim** i **linearnim** nastavnim materijalima koji su ponuđeni studentu na korištenje **bez mogućnosti interakcije** ili **kreativnih** aktivnosti. Karakteristika i problem ovakvih sustava je **napuštanje tečaja** zbog manjka motivacije, zastarjelog i kompleksnog grafičkog sučelja te nejasnih kontrola. Ovakav sustav, navode autori Kovacova i Vackova (2015.) može biti efikasan, uz znatne napore i prilagodbu. Uključivanje **socijalnih medija** u proces e-učenja rezultira **personaliziranim** i **distribuiranim** obrazovnim modelom koji generira i upotpunjuje obrazovni sadržaj na temelju korisnika koji su povezani u sustav. E-učenje 1.0 predstavlja **jednosmjernu komunikaciju** koja je temeljena na nastavnikovoj distribuciji obrazovnih materijala, postavljenih na web mjestima koja su dostupna studentima za pristup materijala, čime se može zaključiti kako je e-učenje 1.0 usmjereno osiguravanju obrazovnih nastavnih materijala studentima, **bez** dodatnih mogućnosti **interakcije**, te **stvaranja** ili **uređivanja** materijala (Hussain, 2012.).

Prema Kovacovoj i Vackovoj (2015.) naglasak e-učenja 2.0 je na **suradnji, komunikaciji** i **dijeljenju** informacija. Hussain (2012.) ističe kako razvojem web 2.0 alata i tehnologije, virtualan obrazovni prostor počinje uključivati kolaboracijske i komunikacijske alate tipa: **wiki, blog, forum, chat** i druge, s ciljem **interakcije**, poticanja **dvosmjerne komunikacije** te **uređivanja** informacija i **kreiranje** novih znanja.

Hussain (2012.) postavlja pitanje je li korektno navesti kako je **e-učenje 3.0** spoje **e-učenja 2.0** i **web 3.0 tehnologije**. U nastavku teksta navode se neke od glavnih web 3.0 mogućnosti kao što su: **Inteligentni / Semantički Web; otvoreni programski pristup** i **interoperabilnost** između uređaja i različitih platformi; **Decentralizirana**, globalna spremišta podataka podržana

"Cloud" tehnologijom, te **3D vizualizacija** podataka i obrazovnih prostora. Tehnologija uključena u web 3.0 sustav stavljena je u usporedbu s **konektivističkom teorijom** učenja koju je moguće pronaći u tablici 14.

Kovacova i Vackova (2015.) navode kako je E-učenje 3.0 **eksperimentalan koncept** koji se bazira na e-učenju 2.0 upotpunjenom sa **semantičkim sustavom klasifikacija informacija**. Web baziran na semantičkoj tehnologiji korisnicima omogućuje **brzo, precizno i kompleksno** pretraživanje informacija i znanja. Semantički web predstavlja temelje za kreiranje **inteligentnih obrazovnih** sustava koji uvelike mogu promijeniti način na koji pojedinci dijele informacije i percipiraju znanje.

Razvojem "Cloud" tehnologije, **inteligentnog filtriranja, virtualnih skladišta** podataka, **ekrana visokih rezolucija**, prepoznavanja naprednih **gestikulacija i 3D dodirnih korisničkih sučelja** istraživači navodi na proučavanje novijih metoda obrazovanja pod nazivom **e-učenje 3.0**. Hussain (2012.) nadalje ističe kako se uz pomoć **umjetne inteligencije i rudarenje podataka** može osigurati **dublje** i bolje **razumijevanje** nastavnih materijala i samog obrazovnog procesa. Završna misao je kako tehnološke mogućnosti Weba 3.0 omogućuju **inteligentnu kolaboraciju** u vrlo detaljnom **3D obrazovnom okruženju** kojemu se može pristupiti s bilo kojeg suvremenog električnog uređaja, s bilo kojeg mjesta koje podržava IKT te u bilo kojem trenutku, čime se osigurava **funkcioniranje semantičkih mogućnosti** za dohvatom **globalnih baza podataka i znanja**.

Hussain (2012.) napominje važne elemente koji bi mogli predstavljati probleme prilikom implementacije suvremene tehnologije u procesu e-učenja 3.0. Prvi problem o kojem treba voditi računa je **rizik od gubitka privatnosti** podataka zbog različitosti u **zakonima** koji variraju od države do države. Prethodnom slijedi **etička dilema** zbog privatnosti i gubitka kontrole nad informacijama, gdje u korist navedenog ide i problem nedostatka **mogućnosti sigurnosnih** provjera svih dostupnih podataka. Problem je u nepostojanju **standarda i nejasnim zahtjevima** za osiguravanje kvalitetne web infrastrukture za ljude s posebnim potrebama. Također, problem je i određeni broj nastavnika koji još uvijek **nisu savladali** web 1.0 i web 2.0 alate. **Otpor** koji postoji po pitanju novih tehnologija, prilagodbe i mijenjanja načina na koji nastavnik pronalazi, kreira i prenosi znanje je **prekretnica** o kojoj isto tako treba voditi računa. Međuodnos generacija weba i e-učenja prikazan je u tablici 13.

Prema Kovacovoj i Vackovoj (2015.) **e-učenje 4.0** predstavlja konceptualan pojam koji se temelji na **umjetnoj inteligenciji** koja bi trebala osigurati **osnovne kognitivne potrebe ljudi**. Navedena tehnologija mogla bi podržavati razvoj kolektivne inteligencije koja bi proširila postojeću **obrazovnu mrežu, sustave znanja, virtualnu i proširenu stvarnost**. Tehnologija utječe i mijenja obrazovnu teoriju i praksu te je važno pratiti daljnja znanstvena i stručna istraživanja teme.

Tablica 13. Međuodnos generacija weba i e-učenja (prilagođeno prema Hussain, 2012.)

Web			E-učenje	
Verzija	Koncept	Tehnologije	Koncept	Tehnologije
Web 1.0	Samo čitanje ili samo pisanje, Web baziran na dokumentima	HTML, HTTP, URL	Upravljanje sadržajem, jednosmjerne aktivnosti	CBT, CMS, eKnjige, VLE
Web 2.0	Čitanje / Pisanje Socijalni Web	Dinamične web tehnologije, ASP, AJAX, Podcasts, SNS	Mješovito učenje, uređivanje sadržaja, multimedijски sadržaj, dvosmjerne aktivnosti,	LCMS, socijalne mreže, video konferencije, VLE, povezivanje
Web 3.0	Čitanje / Pisanje / dohvaćanje / surađivanje velikih skupova podataka, povezani podaci	RDF, XML, OWL, 3D, Second Life	Orijentiranost studentu, U-učenje, reprezentacija znanja	PLE, Socijalni semantički Web, Second Life, osobni avatari

2.2. PEDAGOŠKI ASPEKTI E-UČENJA

Čukušić i Jadrić (2012.) navode kako obrazovanje poučava način na koji ljudi uče te istražuju kako na učenje utječe komunikacija, dizajn tečaja i nastavnog plana, ocjenjivanje i motivacija. Navode kako: "Jedan od dugoročnih ciljeva obrazovanja jest osiguravanje pristupačnog, dostupnog, efikasnog i efektivnog podučavanja"; te kako postoje brojne ideje i koncepti koji opisuju kako pojedinci uče korištenjem *online* sustava.

Čukušić i Jadrić (2012.) govore kako je za proces učenja bitno da su studenti kao polaznici **uključeni i aktivni** u nastavnom procesu, te kako **motivacija** bitno utječe na **ishode naučenog**. **Nastavni materijali i metode** prenošenja znanja trebali bi biti individualizirani te prilagođeni **polaznicima** i trenutnoj situaciji. Nastavnik bi trebao biti prethodno upoznat s teorijama učenja kao što su: biheviorizam, kognitivizam, konstruktivizam i konektivizam. Pregledom literature vidljiv je pomak prema konstruktivističkom pristupu e-učenja gdje se studentima daje mogućnost stvaranja vlastitih informacija i znanja na temelju *online* nastavnih materijala.

2.2.1. Pedagoške teorije i e-učenje

2.2.1.1. Biheviorizam

Bihevioristička teorija orijentira se na promjene u ponašanju koje su uzrokovane učenjem. Uzorak željenog ponašanja se ponavlja sve dok ne postane automatiziranim, Zhang (2003.). Watson, Reinemeyer i Swenson (1999.) navode kako su proučavali odnose između **situacije** i **reakcije** smatra se jednim od najznačajnijih istraživača i predstavnika biheviorizma uz E. L. Thorndike koji je otkrio tzv. zakon efekta (eng. *law of effect*) prema kojemu je dokazano kako svaka aktivnost koja u ispitaniku **izaziva zadovoljstvo** biva s većom vjerojatnošću **ponovljeno**. Christa (1999.) navodi da se navedenim autorima pridružuje i B. F. Skinner koji je proučavao i razvio principe tzv. **instrumentalnog uvjetovanja** kojim se, pomoću sustava nagrađivanja, mogu uzrokovati željeni **oblici** i **promjene** u **ponašanju**.

Čukušić i Jadrić (2012.) navode kako je prema biheviorističkom pristupu učenje **skup promjena** koje se događaju u pojedincu **uslijed** procesa **učenja u okolini**. Učenje je aktivnost **memoriranja, demonstriranja i oponašanja** uz koje se veže sustav **nagrađivanja** i unaprijed isplanirani **obrasci motiviranja** pojedinca. Nastavni materijali koji se temelje na ovom principu imaju osigurano prikladno **grafičko sučelje**, pažljivo osmišljene **grafičke** i **tekstualne** nastavne **elemente** koji mogu se mijenjati i kontrolirati s ciljem što **boljeg pamćenja** pojedinca. Unutar ove teorije učenja, naglasak se stavlja na **nagrađivanju pojedinca** za točan odgovor.

Ovakav proces učenja prati samo **točne odgovore** na postavljena pitanja ili situacije, gdje ujedno i **nije važno** je li student uistinu **shvatio tematiku**. Također, postoje podijeljena mišljenja o tome je li bihevioristički pristup prikladan za multimedijско-interaktivne nastavne materijale s obzirom na to kako se mnogi motivacijski elementi pripisuju ekstrinzičnim utjecajima.

Za efikasnije provođenje biheviorističkog pristupa u e-učenju navode se sljedeće smjernice:

- Jasno isticanje **ishoda učenja** za samokontrolu i upoznavanje s nastavnom temom.
- Testiranje polaznika uz osiguravanje povratne **informacije o uspješnosti** učenja.
- Testiranje treba biti **unutar sustava** za e-učenje i **vidljivo prikazano** u svrhu planiranja.
- Materijali trebaju biti posloženi kako bi **motivirali polaznike** i to od jednostavnijih, općenitih i poznatih pojmova prema specifičnim, složenim i nepoznatim pojmovima.

Aktivnost učenja koja je povezana s kreiranjem **asocijacija** između određenih **podražaja** i **reakcija** organizma, razvijena je u prvoj polovici 20. stoljeća pod nazivom **bihevioristički pristup učenju**. Pokazao je važnu poveznicu između **nagrađivanja** i **učenja** gdje je vidljivo kako ako se određena aktivnost **češće nagrađuje**, ona će se vjerojatnije **brže naučiti** i **ponoviti**. Suprotno isto vrijedi, ako nagrada za određene reakcije izostaje, onda se takve reakcije gase ili postaju sve rjeđe (CARNet: Biheviorizam 2016.).

Biheviorizam kao teorija učenja nalaže kako poučavanje treba podijeliti u manje korake koji su pažljivo planirani. Bihevioristički pristup u obrazovanju očituje se prema Tomić (2012.):

- redovito korištenje testova, kvizova i sličnih metoda procjene znanja.
- planiranje i provođenje aktivnosti kojim se polaznik e-tečaja pohvaljuje i nagrađuje.
- uskraćivanje nagrade ili provedbu aktivnosti kažnjavanja zbog neželjenog ponašanja.

2.2.1.2. Kognitivizam

Kognitivna teorija učenja se umjesto na samo učenje, orijentira na razumijevanje. Temelji se na strukturnim shemama koje studenti sami kreiraju, Zhang (2003.). Presnell (1999.) ističe kako je istaknuti istraživač kognitivnog područja J. Piaget, koji je smatrao kako **pojedinač** kroz učenje i osobni razvoja **izgrađuje** specifične kognitivne strukture, tzv. "**mentalne mape**" ili sheme, na temelju kojih **zaključuje** i **reagira** na podražaje **iz okoline**.

Vygodskaya i Veresov (2001.), McLeod (2014.) navode kako je L. Vygotsky razvio koncept **socijalnog učenja**. U ideji socijalnog učenja naglašava se komponenta **društvene kulture** u kojoj se pojedinac razvija, isto kao i komponenta učenja koja se provodi između onog **što je poznato** i onog što **može biti naučeno**. Ostali predstavnici kognitivizma prema Kurt (2011.) i Clark (2014.) su R. Gagne, koji je utemeljio **preporuke** kako se odnositi prema **poučavanju vještine**, te R. Spiro, koji je utemeljio teoriju **kognitivne fleksibilnosti** (eng. *cognitive flexibility theory*) kao vještine za **spontano mijenjanje** znanja pojedinca.

Kognitivizam kao teorija učenja vodi k oblikovanju novih misaonih shema i prilagođavanju postojećih upotrebom nekih od kognitivističkih načela koja su navedena u nastavku teksta:

- korištenje primjera i modela za usvajanje i povezivanje pojmova,
- kategorizacija i komparacija postojećih i novih znanja,
- izrada dijagrama i shema,
- oslanjanje na ranije naučeno u stjecanju novih znanja,
- kombiniranje načina učenja itd.

Kognitivisti smatraju kako je proces učenja pod utjecajem **unutarnjih konstrukata** koji utječu na **motivaciju, pažnju, percepciju i pamćenje**. Učenje unutar ove teorije svodi se na **potrebu** pojedinca za **učenjem** iz čega proizlazi aktivno analiziranje i procesiranje informacija, viši stupanj **motivacije** i **razumijevanja**. Kognitivisti vide učenje kao samovoljnu aktivnost koja se temelji na pozornosti i uloženoj energiji, a kao rezultat navedenog je percepcija, privlačenje pažnje i motiviranost polaznika. Naglasak je na **procesiranju informacija** gdje je **razumijevanje** i **znanje** krajnji i nezaobilazni cilj koji uvelike ovisi o **sposobnostima** za **razlučivanje** pojedinca. Uz sposobnosti, posebno važna komponenta je i **uloženi trudi, intrinzična motivacija**, te **postojeće znanje** koje polaznik ima. Navedeni pristup ima primjenu u multimedijski-interaktivnim nastavnim materijalima zbog pažljivog dizajniranja korisničkog sučelja i postavljanja detalja u svrhu poticanja motivacije polaznika e-tečaja.

Proces koji je promatran kao aktivno **pohranjivanje, organiziranje, obrađivanje** te **traženje veza** između informacija temeljen na misaonim aktivnostima predstavlja temelj kognitivističke teorije učenja. Osnovna ideja učenja prema kognitivizmu je u razvijanju **kognitivnih shema** ili **misaonih struktura** koje predstavljaju vanjske ili unutarnje situacije, procese ili pojave. Navedeni pristup o razvijanju kognitivnih shema ili misaonih struktura koje su vezane za vanjske ili unutarnje pojave ili procese, potječu iz prve polovice 20. stoljeća.

Ideja i pristup govore kako je učenje povezano s **kreiranjem novih shema** i prilagodbom postojećih shema **novim situacijama** i **potrebama**. Kako bi kognitivna teorija imala uspjeha u poučavanju potrebno je prethodno utvrditi **vrstu** i **stupanj razvijenosti sheme** koju studenti posjeduju te **oblikovati** proces i sadržaj učenja tako da se **postojeće** sheme **dalje razvijaju**, **mijenjaju** i **dopunjuju**. Novo nastale misaone sheme se ugrađuju u postojeće znanje i/ili postojeće sheme bivaju promijenjene i prilagođene kako bi se u njih uklopilo novo iskustvo. S vremenom sheme koje pojedinac posjeduje postaju sadržajno **sve bogatije, kompleksnije** i **više strukturirane** (CARNet: Kognitivizam 2016.).

Smjernice za primjenu kognitivističkog pristupa e-učenju nalaze se u nastavku teksta:

- **Informacije** trebaju biti **rascjepkane** kako bi se lakše procesuirale i zapamtile.
- Treba se **uskладiti s polaznicima** po pitanju korištene strategije (analiza, sinteza, vrednovanje) koja čini pomak k dugotrajnom pamćenju.
- *Online nastavni materijali* trebaju uključivati aktivnosti **koje studenti mogu**, ali i **ne moraju** koristiti ovisno o njihovom preferiranom stilu učenja.
- Informacije se trebaju prikazati u **što je više oblika i formata moguće** kako bi se što više udovoljilo polaznicima za produblivanjem dugotrajnog pamćenja.
- Potrebno je osmisлити i primjenjivati strategije za **poticanje intrinzične** i **ekstrinzične motivacije** polaznika.
- U nastavnim materijalima preporučuje se korištenje **praktičnih** i polaznicima **poznatih primjera**.

2.2.1.3. Konstruktivizam

Konstruktivizam kao teorija učenja govori o učenju kao o **individualnom procesu** u kojemu se polazniku e-tečaja treba **osigurati** mogućnost upotpunjavanje **postojećeg** i **samostalnog kreiranja novog znanja**. Predstavnici ove teorije smatraju kako se znanje ne može izravno prenijeti, te kako se **informacije** trebaju razložiti **na male cjeline** koje student **prikuplja** i **slaže**, prema **njemu smislenom redu**, u **novo znanje**. Naglasak je na aktivnom sudjelovanju i promišljanju studenta pri čemu, student može birati način na koji želi učiti (Zhang, 2003.).

Polaznici su u središtu obrazovnog procesa te sami **preuzimaju odgovornost** za razinu i kvalitetu naučenog, dok je **uloga nastavnika marginalna** u vidu korištenja prikladnih strategija, alata ili savjeta za uspješno e-učenje.

Sustav **davanja gotovih instrukcija** kako nešto napraviti ili prihvatiti kao činjenicu se **izbjegava**, te je naglasak na usmjeravanju polaznika prema relevantnim informacijama na temelju kojih će sam ili u suradnji s ostalim sudionicima e-tečaja (nastavnika, ostalih studenata) doći do zaključaka i novog znanja. Znanje se **kreira, mijenja, prilagođava, nadopunjuje i ne predstavlja objektivno činjenično stanje** jer se temelji na prijašnjim znanjima pojedinca i novonastalim situacijama koje se tek istražuju. Proces je dugotrajan i potrebno je uključiti vrijeme u kojemu se vidi je li novonastali koncept ispravan i spreman za nadogradnju nastavkom tečaja. U tu svrhu mogu pomoći diskusijski forumi, usporedba drugih ideja i testiranje znanja u stvarnim situacijama.

Uloga nastavnika je biti voditelj koji studente usmjerava **samostalnom otkrivanju** načela i zakona o predodčenim sadržajima koje uče. Nastavnik treba **osigurati i uskladiti** oblik informacija, koje studenti proučavaju, **razini već usvojenog znanja** grupe. Prvi korak je uvesti grupu u novu obrazovnu cjelinu i područje te im pomoći u otkrivanju kako će najlakše i najučinkovitije stjecati novo znanje. Naglasak treba biti na **samostalno-problemsko orijentiranom radu** koji je povezan s nastavnom cjelinom koja se treba razumjeti i naučiti. **Zadaci** trebaju biti **sve složeniji i utemeljeni u realnim situacijama**. Ideja je kako se studenti nakon nekog vremena trebaju osamostaliti i biti u mogućnosti sami nastaviti proces učenja. Za efikasnu primjenu modela, studenti trebaju biti **usmjereni na samostalan rad** i učenje u praksi s naglaskom na poticanje kreiranja novih pojmova koji se povezuju u ranije usvojene sheme i ugrađuju u složene strukture na osnovi kognitivne aktivnosti te praktičnog rada i iskustva studenata (CARNet: Konstruktivizam 2016.).

Konstruktivizam kao teorija učenja orijentirana je **izgradnji znanja** na temelju **vlastitog iskustva** pa je zbog toga način stjecanja znanja individualan kod svakog pojedinca. Naglasak koji se pridodaje radu sa studentima je taj da se studentima omogući što je više moguće **samostalan odabir**, obrada **informacija**, stvaranje **hipoteza i odluka**. Navedeno se temelji na osobnom mentalnom modelu (kognitivne strukture, sheme) koji je **vezan za vlastito iskustvo pojedinca** (Tomić, 2012.).

Konstruktivizam, kao jedna od kognitivnih teorija učenja, posebno je popularna u e-učenju prema kojem **znanje nastaje aktivnošću studenta**, a proces učenja je temeljen na **(re)organizaciji shema** koje je **student kreirao** za određene činjenice, probleme, stanja ili pojave u svojoj okolini.

S obzirom na to kako studenti sami kreiraju svoje znanje, **uloga nastavnika** je tu kako bi osigurao **potrebne izvore informacija, nastavne materijale** te usmjerio i vodio obrazovne aktivnosti. Društvena sredina u kojoj učenik stječe znanja od velike je važnosti za proces učenja, s obzirom na to kako se znanje stječe u socijalnom kontekstu (CARNet: Konstruktivizam 2016.). Jedan od najpoznatijih predstavnika konstruktivizma, prema Smith (2002.) je *J. Bruner* koji navodi da se poučavanje treba:

- temeljiti na **iskustvima i kontekstima** u kojima studenti žele učiti,
- **strukturirati** tako da nova znanja **mijenjaju** ili **nadograđuju postojeća**, ovisno o mogućnostima studenata,
- oblikovati tako da se pred studente stavljaju **kratki izazovi** kojima bi se **povezivale spona** između stečenog i dostupnog znanja te **popunjavale praznine** u već stečenom znanju.

Navedeni princip stjecanja znanja nije lako provediv zbog **stavova nastavnika**, ali i **navika polaznika**. Ideja dobre prakse u okruženju e-učenja koje je podržano konstruktivističkim metodama poučavanja, predstavlja korištenje **mobilnih uređaja** u nastavnom okruženju. Navedeni način omogućuje **slobodno kretanje po učionici, interaktivnost i razgovor** s ostalim polaznicima e-tečaja gdje je nastavnik **kreator** nastavnih materijala i **moderator** obrazovne okoline.

Smjernice za konstruktivistički pristup e-učenju nalaze se u nastavku rada:

- Učenje treba biti aktivan proces koji studente **potiče na razmišljanje**.
- Polaznici trebaju **graditi vlastito** znanje na temelju **segmentiranih informacija** prezentirane u nastavnim materijalima, te **komunicirati** s ostalim polaznicima o svojim idejama i konceptima.
- Potrebno je poticati **kolaboracijske aktivnosti** jer se tako može učiti od drugih polaznika i navedeni način je bliži stvarnim životnim situacijama.
- Polaznici trebaju imati **dovoljno vremena** za razmišljanje o informacijama i izloženim problemskim zadacima, te im treba biti omogućena **kontrola nad učenjem**.
- **Nastavni materijali** trebaju biti **bliski polaznicima i uključivati** što je više moguće **primjera**.
- Učenje treba biti **interaktivno i intuitivno** čime se ostvaruje viša razina učenja.

2.2.1.4. Konektivizam

Navedene teorije učenja (biheviorizam, kognitivizam i konstruktivizam) razvijene su u vrijeme kada je naglasak na informacijsko-komunikacijsku tehnologiju bio znatno manji. **Tehnologija** koja se danas široko koristi, omogućuje **stvaranje novih znanja** pomoću **neuronskih mreža**, specijaliziranih **baza podataka** i sl. gdje je cilj **povezivanje** specijaliziranih **grupa informacija**. Princip na koji se nova znanja kreiraju je možda i važniji od samog znanja, gdje **protok informacija** predstavlja **ključan element**.

Dostupna infrastruktura i razvoj informacijsko-komunikacijske tehnologije osigurava ideju konektivizma i predstavlja preduvjete za učinkoviti razvoj dinamičnih sustava za e-učenje. Učenje na temelju teorije konektivizma stvara okružje gdje **polaznik nije u središtu** obrazovnog procesa **niti je učenje** kao aktivnost **individualna**. Naglasak je na **suradnji** i efikasnom **korištenju** dostupne **tehnologije** i **alata**, kao što su društvene mreže, u svrhu **dijeljenja, proširivanja i mijenjanja** postojećih spoznaja.

Hussain (2012.) postavlja pitanje **je li za web 3.0 potrebno** proučiti i **razviti novu teoriju učenja**? Teorija učenja odnosi se na koncept koji pomaže u sagledavanju načina i uzroka promjena u obrazovanju. Generalno gledano, unutar obrazovanja postoje četiri teorije učenja, Biheviorizam, Kognitivizam, Konstruktivizam i Konektivizam. **Biheviorizam** se može povezati s web 1.0. **Kognitivizam** se okreće pojedincima, te studenta smatra pokretačem informacijskog procesiranja. **Konstruktivizam** predstavlja ideju gdje student stvara znanje za vrijeme dok pokušava kreirati značenje nad svojim iskustvima. Web 2.0 i e-učenje 2.0 utemeljeno je na **konektivizmu** gdje bi se za web 3.0 u razmatranje trebali uključiti i **inteligentni agenti, mobilno stvaranje i razmjena znanja**, te alati za **filtriranje** i **rašćlanjivanje** bitnog umjesto ljudi. Tablični prikaz navedenih teorija prikazan je u tablici 15.

Konektivizam kao teorija učenja slijedi principe koje Hussain (2012.) navodi u nastavku:

- Učenje i znanje temeljeno je na **različitosti mišljenja**.
- Učenje je proces **povezivanja** specijaliziranih čvorova ili izvora informacija.
- **Učenje** se može **dogadati u elektroničkim uređajima**.
- **Buduća znanja** su važnija nego ono što je trenutno poznato.
- Njegovanje i održavanje **veza** je potrebno kako bi se olakšao **proces stalnog učenje**.
- Sposobnost **prepoznavanje veze** između polja, ideje i koncepata je posebno važna.
- **Točnosti i suvremenost** znanja je namjera svih aktivnosti učenja konektivista.

Tablica 14. Podržanost osnovnih principa konektivizma od strane Web 3.0 tehnologije (prilagođeno prema Hussain, 2012.)

Web 3.0 tehnologije korištene u e-učenju 3.0	Osnovni principi konektivizma
Socijalne semantičke mreže, otvorenost i interoperabilnost	Učenje i znanje temeljeno je na različitosti mišljenja
Veliki podaci ili globalni repozitorij podataka, povezani podaci, Cloud sustavi, proširena smart mobilna tehnologija	Učenje je proces povezivanja specijaliziranih čvorova ili informacijskih izvora. Naglasak je na novim znanjima.
Računalno učenje, umjetna inteligencija, osobni avatari, 3D vizualizacija i interakcija	Učenje se može događati u elektroničkim uređajima.
Semantički web, kontrola informacija	Buduća znanja su važnija nego ono što je trenutno poznato.
Semantički web, kolaborativno inteligentno filtriranje podataka, informacija i znanja	Njegovanje i održavanje veza je potrebno kako bi se olakšao proces stalnog učenje.
	Sposobnost prepoznavanje veze između polja, ideje i koncepata je posebno važna.

Tablica 15. Tablični prikaz teorija učenja (prilagođeno prema Bíró, 2014.)

Komponente učenja	Bihevioristička teorija	Kognitivna teorija	Konstrukzivna teorija	Konektivna teorija
Student / Polaznik	instinktivna aktivnost	svjesna aktivnost	svjesna aktivnost	svjesna aktivnost
Motivacija	ekstrinzična	intrinzična	intrinzična	ekstrinzična
Znanje	vanjsko	unutarnje	unutarnje	vanjsko
Proces učenja	uzrokovan okolinom	ad hoc samostalan	sistematično samostalan	ad hoc društven
Naglasak obrazovnog sustava	okolina i ponašanje polaznika	kognitivne aktivnosti polaznika	kognitivne aktivnosti s naglaskom na ranije znanje	dinamika umrežavanja s naglaskom na raspodjeli znanja
Uključenost	pojedinačna	pojedinačna	pojedinačna	temeljena na mreži polaznika
Obrazovni sustav je navođen od	nastavnika	nastavnika	nastavnika	polaznika i nastavnika
Stav nastavnika	aktivan	aktivan	neaktivan	neaktivan
Stav polaznika	neaktivan	neaktivan	aktivan	proaktivan
Povratna informacija	pojedinačna	pojedinačna	pojedinačna	temeljena na mreži polaznika

2.2.2. Teorije i vrste procjene znanja

Uz navedene, razvijeni su i drugi teorijski modeli za tumačenje i unapređenje procesa učenja i poučavanja koji se mogu koristiti prema potrebama i mogućnosti ovisno o specifičnosti obrazovne situacije. U nastavku rada unutar tablice 16. navode se nazivi i osnovni opisi teorija.

Tablica 16. Naziv i opis teorijskih modela koji mogu biti korišteni za oblikovanje i unapređenje procesa učenja (sastavio autor disertacije)

Naziv teorijskog modela	Predstavnik i opis teorije
Teorija dvostrukog kodiranja (<i>dual coding theory</i>)	Teoriju je razvio je A. Pavio prema kojem postoje dva kognitivna podsustava od kojih je jedan odgovoran za obradu vizualnih informacija o objektima, a drugi je specijaliziran za jezik. Osnovno načelo teorije dvostrukog kodiranja jest da je prisjećanje ili prepoznavanje objekata učinkovitije ako su informacije prethodno prezentirane na oba načina, tj. vizualno i verbalno. Primjena ove teorije je moguća u različitim kognitivnim područjima kao što su učenje pojmova i jezika, rješavanje problema i sl. (Tomić, 2012.; Kearsley i Culatta, 2016.)
Teorija poučavanja uz pomoć "sidra" (<i>anchored instruction</i>)	Teoriju je razvio J. Bransford , gdje se aktivnosti poučavanja i učenja izgrađuju oko neke problemske situacije ili analize slučaja. Naime, ako studenti iz nekog područja nemaju već usvojena znanja, obično su primorani učiti izvan konteksta što je nedjelotvorno i stvara poteškoće. Zato se koriste primjeri, analize slučaja ili problemske situacije koje predstavljaju "sidro" za procese stjecanja novih znanja (Tomić, 2012.; Kearsley i Culatta, 2016.)
Teorija razrade (<i>elaboration theory</i>)	Teoriju je razvio C. Reigeluth , poučavanje treba biti organizirano u rastućim intervalima složenosti za optimalno učenje. Temeljna je ideja ove teorije kako učenik treba razviti smisleni kontekst (temelj/pozadinu) s kojim se potom sjedinjavaju nove ideje i vještine (Kearsley i Culatta, 2016.)
Teorija višestrukih inteligencija (<i>multiple intelligences</i>)	Teoriju je razvio H. Gardner , u kojoj navodi da svaki pojedinac posjeduje više različitih oblika inteligencija, a svaki taj oblik je razvijen do određene razine. Gardner razmatra sedam glavnih oblika inteligencija: lingvističku, glazbenu, logičko-matematičku, prostornu, tjelesnu, intrapersonalnu i interpersonalnu. Prema toj teoriji, učenje se treba fokusirati na neku konkretnu inteligenciju pojedine osobe (Smith, 2008.)

Tablica 16. Naziv i opis teorijskih modela koji mogu biti korišteni za oblikovanje i unapređenje procesa učenja (nastavak tablice)

Naziv teorijskog modela	Predstavnik i opis teorije
Teorija socijalnog učenja (<i>social learning</i>)	Teoriju je razvio A. Bandura , koji ističe kako se znatan dio učenja odvija u interakciji pojedinca i socijalne okoline, tj. promatranjem i modeliranjem tuđeg ponašanja te imitacijom drugih pojedinaca (Bandura 1971.; Tomić, 2012.; Kearsley i Culatta, 2016.)
Teorija kognitivnog pripravištva (<i>cognitive apprenticeship</i>)	Teoriju su razvili A. Collins, J.S. Brown , koji govore kako formalno školovanje ne uspijeva u poučavanju složenih kognitivnih vještina. U odnosima između nastavnika i studenta (kao i u odnosu "majstora" i "šegрта") nastavnik otkriva studentu način svojeg razmišljanja i demonstrira vještine koje su potrebne za obavljanje neke specijalističke aktivnosti (Collins i suradnici, 1987. i 1989.; Berryman, 1991.)
Računalom podržano suradničko učenje (<i>CSCL - computer supported collaborative learning</i>)	Teorija je razvijena od strane T. Koschmann , gdje se istražuje se uporaba informacijskih i komunikacijskih tehnologija (ICT) kao sredstava kojima se posreduje u primjeni različitih suradničkih metoda u nastavi (npr. učenje od vršnjaka, simulacije i igre, projekti i problemsko učenje). Pritom je cilj podržati učenike/studente u zajedničkom učenju i uporabom tehnologije ostvariti grupnu dinamiku koja nije moguća u interakciji licem-u-lice (Stahl, 2006.; Tomić, 2012.)

Simuth i Sarmany-Schuller (2012.) navode kako postoji **mali broj istraživanja** koja govore o **pedagoškom i psihološkom aspektu** u području **e-učenja**. Istraživanje koje Simuth i Sarmany-Schuller iznose vezano je za visokoškolske institucije po pitanju tehnologije, komunikacije sa sudionicima tečaja, nastavnim materijalima i nastavnim aktivnostima studenata. Broj ispitanika je 234, prosječne dobne granice od 22.7 godina. Istraživanje je pokazalo kako **tehnološka rješenja** i njihova primjena **ne predstavljaju probleme** u e-učenju. **Nastavni materijali i nastavne aktivnosti** predstavljaju **poteškoću**, dok **socijalni aspekt** (*online* komunikacija s ostalim studentima i nastavnikom) predstavlja **vrlo veliku poteškoću** i prepreku kada je e-učenje u pitanju. **Informacijsko-komunikacijska tehnologija nije element** koji **doprinosi** kvaliteti *online* obrazovanja. Studenti su reagirali na **socijalne, komunikacijske i didaktičke** aspekte e-učenja čime je naglasak i stavljen na istraživanje tih elemenata.

Istraživanje je prošireno s još 80 studenata kojima su postavljena samo pitanja vezana uz socijalne, komunikacijske i didaktičke aspekte e-učenja te je raniji zaključak potvrđen.

Studenti osjećaju kako su izloženi **pasivnom obrazovnom sustavu**, popraćenom nedostatkom kvalitetne literature i **manjkom mogućnosti za komunikaciju i kolaboraciju** s nastavnikom i drugim studentima istog e-tečaja. Zaključuje se kako IKT ne predstavlja problem *online* obrazovanja te se navodi sedam principa e-pedagogije koji su navedeni u nastavku rada.

Sedam principa e-pedagogije se temelje na:

- **Omogućiti i osigurati** regularnu međusobnu **komunikaciju** između studenata, te između studenata i nastavnika.
- **Razviti suradnju** između studenata.
- Osigurati studentima više **povratnih informacija** o nastavnim i nenastavnim aktivnostima uz klasičan sustav evaluacije.
- Osigurati **pozitivnu i poticajnu** obrazovnu **atmosferu i okolinu**.
- **Poštivati raznolikost** talenata i stilova učenja prilikom kreiranja nastavnih aktivnosti i materijala.
- Osigurati **jasne ishode i ciljeve učenja** te ih prezentirati studentima na početku e-tečaja.
- **Osigurati** svim korisnicima **pravilnu izobrazbu** za korištenje sustava za e-učenje.

2.2.3. Ishodi učenja

Prema **Hrvatskom Kvalifikacijskom Okviru** (2015.): "*Ishodi učenja* (eng. *learning outcomes*) iskazuju razinu kompetencije koju je student postigao i koja je potvrđena vrednovanjem. Riječ je o navodima o tome što pojedinac zna, razumije i može učiniti po završenom procesu učenja. Oblikuje ih nastavno osoblje u suradnji sa studentima i drugim dionicima. Da bi se olakšalo vrednovanje, navodi trebaju biti provjerljivi." **Adam** (2004.) definira kako su ishodi učenja izjave o tome što student treba znati, razumjeti i biti u stanju pokazati na kraju iskustva učenja. **Bruke** (2002.) u svojoj knjizi ističe kako je prednost korištenja ishoda učenja u tome što osigurava bolju informiranost svim sudionicima obrazovnog procesa prilikom donošenja odluke o pristupanju nastavnim sadržajima pogotovo u slučaju izbornih kolegija. **Čižmešija** (2008.) ističe kako su ishodi učenja jasno i precizno napisane izjave o tome što bi student trebao znati, razumjeti, moći samostalno napraviti, samostalno vrednovati i sl. po završetku procesa učenja (2008.). **Erjavec** (2008.) govori: "*Ishodi učenja su izjave o tome što se očekuje da student zna, razumije i sposoban je demonstrirati nakon uspješno završenog procesa učenja.*" **Divjak i suradnici** (2009.) uz ranije dvije definicije navode kako su ishodi učenja povezani s mjerljivim pokazateljima razina u nacionalnim i europskim kvalifikacijskim okvirima, te dodaje kako: *Ciljevi učenja određuju što bi nastavnik htio da student nauči i razumije, pa se oni koji se zalažu za poučavanje koje u svom središtu ima studenta* (eng. *student-centered learning*), *radije služe ishodima učenja u organizaciji nastavnog procesa*".

Kada se govori o ishodima učenja, razlikuju se još i ciljevi i kompetencije. Ciljevi su prema Erjavcu (2008.) usmjereni prema poučavanju, te pokazuju što nastavnik planira obuhvatiti nastavnim procesom. Kompetencije su dinamička kombinacija znanja, razumijevanja, vještina i sposobnosti usmjerena studentu koji ih postiže i razvija tijekom procesa poučavanja. Ishode učenja svaki nastavnik definira samostalno za svoj kolegij i odnosi se isključivo na polaznika nastavnog procesa.

Tablica 17. Ishodi učenja s obzirom na sudionike u nastavnom procesu
(kreirao autor disertacije prema Divjak i suradnici, 2009.)

Pomažu nastavniku	Pomažu studentu	Pomažu instituciji
Definirati što se očekuje od polaznika	Kod pronalaska i odabira izbornih kolegija	U poticanju mobilnosti svih sudionika nastavnog procesa
Kod pripreme nastavnih materijala, metoda, oblika i načina provjere postignuća	Objašnjavajući na što se stavlja naglasak	Osigurati vertikalnu i horizontalnu povezanost studijskih programa
Komunicirati s ostalim sudionicima nastavnog procesa	Kod pripreme za provjeru postignuća	Komunicirati sa sveučilištem, društvenom zajednicom i poslodavcima

Erjavec (2008.) navodi kako pravilno napisati ishode učenja te se u nastavku rada navodi primjer: "*Nakon uspješnog svladavanja (ispunjenja, dovršenja, izvršenja, okončanja) kolegija (predmeta, modula) student će biti u stanju (znati, biti osposobljeni, moći) ...*" pri čemu se naglasak stavlja na aktivne glagole.

Tablica 18. Bloomova klasifikacija kognitivnih vještina
prema Anderson i suradnici (2001.) i Divjak i suradnici (2009.)

Kategorija	Definicija	Ponašanje
Znanje	Prisjećanje važnih informacija	Definirati, prepoznati, ponoviti, opisati, identificirati, označiti, izdvojiti, prisjetiti, nabrojiti, imenovati, povezati.
Razumijevanje	Pojašnjavanje važnih informacija	Grupirati, objasniti, dati primjer, predvidjeti, sažeti, diskutirati, izraziti, izvijestiti.
Primjena	Rješavanje zatvorenih problema	Primijeniti, koristiti, prilagoditi, prikupiti, demonstrirati, otkriti, riješiti, upotrijebiti, intervjuirati, rasporediti, izabrati, izračunati.
Analiza	Rješavanje otvorenih problema	Analizirati, razlikovati, provjeriti, usporediti, napraviti dijagram, skicirati, izdvojiti, sortirati, povezati, ispitati, kategorizirati.
Sinteza	Povezivanje dijelova ili ideja u cjelinu	Izgraditi, planirati, kombinirati, kreirati, predložiti, osmisliti, postaviti hipoteze, generalizirati, predvidjeti, napisati, voditi, upravljati, pripremiti, prezentirati.
Evaluacija	Ocjena vrijednosti nečega prema realnoj situaciji uz upotrebu kriterija	Procijeniti, prosuditi, ocijeniti, zaključiti, odabrati, normirati, preporučiti, usporediti, postaviti prioritete.

3. GEMIFIKACIJA E-UČENJA

U ovom poglavlju prvo su prikazane definicije, povezana istraživanja, kao i zaključci o gemifikaciji kao metodi za unapređenje online poučavanja. Poglavlje se nastavlja s pregledom osnovnih gemifikacijskih elemenata koji su uključeni u kasnijim fazama izrade doktorata u obliku empirijskog istraživanja. Slijedi opis pedagoških i psiholoških aspekta uvođenja gemifikacije u nastavu visokoškolskih predmeta. Poglavlje se zaključuje primjerima elemenata računalnih igara u obrazovnom sustavu koji su preuzeti iz literature.

3.1. POJAM I TEORIJSKI OPIS GEMIFIKACIJE E-UČENJA

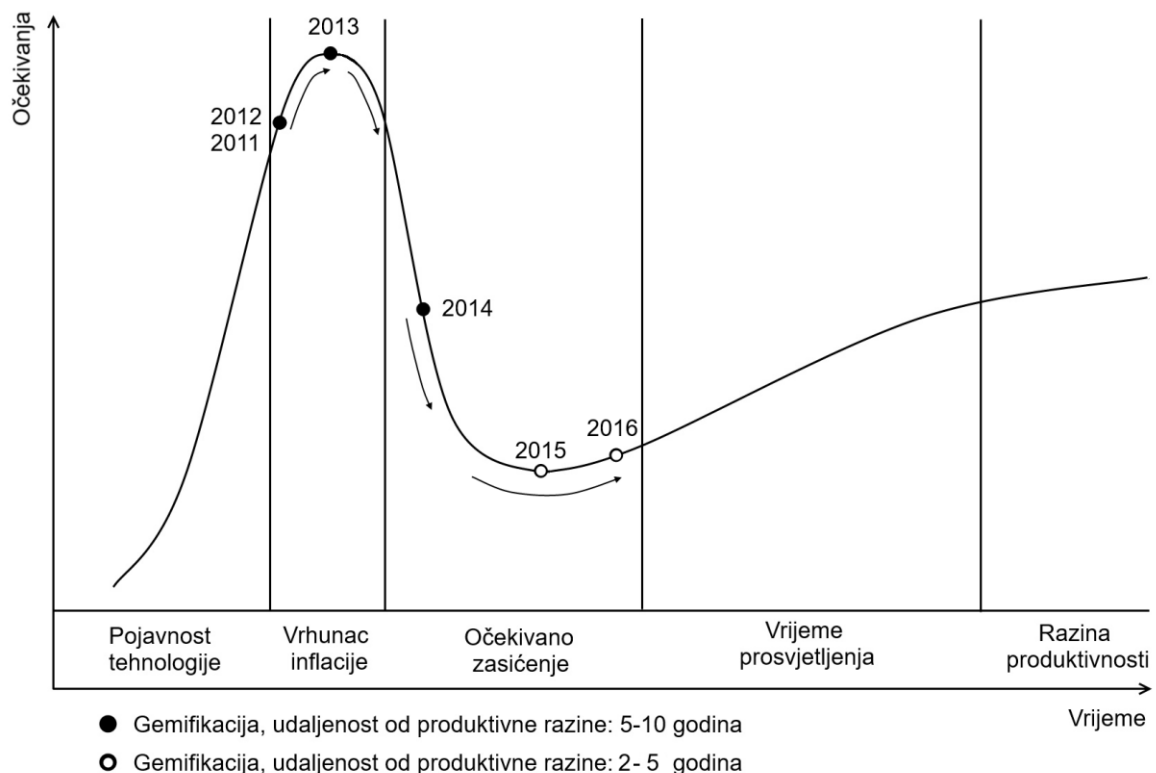
Prije definiranja gemifikacije potrebno je spomenuti kako je uvođenje elemenata računalnih igara u područje koje nije igra među prvima dokumentirao Nick Pelling 2002. godine (Pelling, 2011.; Schönen, 2014.; Vehns, 2014.). Stavrakakis i suradnici (2015.) navode kako se sve do 2010. pojam nije koristio ni dalje istraživao pretežito **zbog sporog razvoja informacijsko komunikacijske tehnologije**. Deterding (2011.) počinje ponovno govoriti o gemifikaciji, koja ubrzo postaje uključena u mnoge profitne ili neprofitne djelatnosti. Deterding sa suradnicima u istraživanjima koje su proveli 2011. godine ističu kako je gemifikacija proces **uvođenja elemenata računalnih igara** u područje koje **nije igra** te predstavlja iznimno brzi rastući trend u poučavanju (Deterding, 2011.; von Schiller, 2015.). Gemifikacija se može definirati i s drugog stajališta, prema Lombriseru (2015.) koji daje sljedeću definiciju gemifikacije: "Korištenje mehanike računalnih igara i korisničkog dizajna u svrhu digitalnog uključivanja i motiviranja korisnika za postizanjem njihovih ciljeva". Osnovni elementi navedene definicije su (Lombriser, 2015.):

- **Mehanika** računalnih igara - pravila, izgled, alati za vođenje korisnika kroz sustav.
- Korisnički **dizajn** - dizajn prema kojemu će korisnik biti u interakciji sa sustavom.
- Digitalna **uključenost** - pojava u kojoj korisnik radije bira interakciju s digitalnim uređajem nego s drugim korisnikom.
- **Motivacija** - promjena ponašanja, inovativan pristup razmišljanja, svladavanje vještina.
- Postizanje **cilja** - usklađivanje cilja korisnika s ciljem sustava, gdje će organizacija indirektno dobiti ispunjenje svojih ciljeva u trenutku kada korisnik ispuni svoje ciljeve.

Sæter i Valle (2013.) navode kako "Gemifikacija predstavlja fenomen koji koristi **mehaniku** računalnih igara, **estetiku** i **logiku** kako bi uključio i **motivirao korisnike** te ih **usmjerio prema učenju i rješavanju** problemskih aktivnosti".

Stokes (2014.) dodaje da, gemifikacija koristi principe igara u svakodnevnim aktivnostima kako bi korisniku omogućila praćenje napretka, uz aktivnosti nagrađivanja i dodatnog motiviranja.

Versteeg (2013.) ističe dodirne točke gemifikacije s marketingom, koje se temelje na lojalnosti korisnika, npr. u sakupljanju bodova i dobivanjem nagrada zauzvat. Gemifikacija je od 2011. godine uključena u Gartnerovu analizu novih inovacijskih tehnologija "*Hype Cycles*" (LeHong i suradnici, 2012.; Lombriser, 2015.) te se 2011. i 2012. nalazi na uzlaznoj putanji suvremenih trendova (Muntean, 2011.; Xu, 2011.) dok je 2013. na samom vrhu inovacijskih tehnologija (van der Meulen, 2013.; Webb, 2013.). Predviđa se kako će 2017. godine tisuću najvećih svjetskih organizacija koristiti elemente računalnih igara kao model za obrazovanje i/ili regrutaciju novih korisnika (Bruke, 2013.). Na slici 14. prikazan je grafikon po uzoru na Gartnerov pokazatelj inovacijskih tehnologija pod nazivom "*Hype Cycles*".



Slika 14. Položaj gemifikacije u odnosu na inovacijski ciklus (prilagođeno prema Gartner, 2011.-2016.)

Slika 14. pokazuje gemifikacijsku tehnologiju u vremenu od **2011. do 2016. godine**. Vidljiv je pravilan ciklus i relativno brzi pomak od početka samog praćenja gamifikacije kao tehnologije. Crna točka kojom je gemifikacija prikazana između 2011. i 2014. godine, na slici 14., predstavlja predviđanje gdje se navodi da će gemifikacija dostići **razinu produktivnosti** u vremenu od **5 do 10 godina**.

Gartner navedenu tvrdnju temelji na analizi tržišta u određenoj godini. Krug kojim je kretanje gemifikacije u 2015. i 2016. godini opisano na slici 14. prikazuje očekivani pomak gemifikacije prema razini produktivnosti. Zbog jednostavnosti iz grafikona su uklonjene sve ostale tehnologije, njihovo kretanje i vrijeme dolaska u razinu produktivnosti.

McGuire (2015.) navodi da je gemifikacija dio mnogih tehnologija koje su usmjerene poboljšanju korisničkog iskustva te imaju veliki i trenutni utjecaj u digitalnom marketingu. Chou (2016.) se ne slaže s navedenim te smatra da **gemifikacija nije tehnologija**, već metodologija. Chou ne podupire mišljenje da je gemifikacija marketinški trend, već **alat za dizajniranje i upravljanje ponašanjem** korisnika (Chou, 2016.). Goasduff i Pettey (2011.), Kumar i Herger (2013.), Muntean (2011.) te mnogi drugi istraživači citiraju Gartnerova istraživanja i tvrdnje u kojima se naglašava kako će većina sustava koji su krenuli s implementacijom elemenata računalnih igara **biti neuspješni**, primarno zbog **lošeg dizajna i povezivanja elemenata računalnih igara s postojećim online rješenjima**.

Gabe Zichermann i Yu-kai Chou su 2010. godine bili među prvima koji su ponovno uočili fenomen uvođenja elemenata računalnih igara u područje koje nije vezano za računalne igre. Gabe je osnivač portala Gamification.org i GSummita te predavač i autor knjiga o gemifikaciji, dok je i Chou kreator *Octalysisa*, sustava za mjerenje stupnja gemificiranosti, te ujedno predavač na sveučilištu Stanford i konzultant za gemifikacijske sustave. Fokusiranje njihovog djelovanja usmjereno je primarno na poslovne i marketinške sustave.

Souza-Concilio i Pacheco (2013.) navode kako je implementacija elemenata računalnih igara vidljiva u različitim područjima, uključujući **obrazovanje, zdravlje i fitness, upravljanje zadacima, održivosti okoliša, znanost, korisničko generirane sadržaje** i dr. Iz navedenih bi se razloga znanstvene i obrazovne ustanove te poslovne organizacije trebale orijentirati na stvaranje interaktivnih i *gemificiranih* rješenja koja potiču kolaboraciju, motivaciju i inovativan pristup rješavanju problema (Rauch, 2012.). Malone i suradnici (2015.) navode rezultate svog istraživanja gdje se iznosi kako je vrijednost gemifikacijskog tržišta 2013. godine iznosila 513 milijuna USD, 2014. bila je 980 milijuna USD, dok 2016. godine iznosi 2.8 milijardi USD (Petridis, 2014.; Xu, 2011.; Yana, 2013.). Projekt Europske unije **Horizon 2020**, koji je raspisan unutar natječaja ICT-21-2014, poziva na istraživanje gemifikacijskih tehnologija te je za istraživanje izdvojeno osam milijuna eura (ICT 2014.). Istraživanje se nastavlja i unutar **Horizonta 2020** za 2016. godinu, a poziv za H2020-ICT-2016-2017 bio je otvoren do 12. travnja 2016. (ICT 2016.).

Postoje principi koji su slični gemifikaciji, među kojima je i pojam "ozbiljna igra" (eng. *serious games*), koja se temelji na elementima i aktivnostima prikazanim kroz okruženje računalne igre. Ovdje se najčešće govori o radnim zadacima koji se rješavaju računalnom igrom. Ozbiljna igra jest igra čija **primarna svrha nije zabava** koja se omogućuje korisniku (Hakulinen, 2015.). Odnos gemifikacije i ozbiljnih igara prikazan je na slici 15.



Slika 15. Klasifikacija gemifikacije (prilagođeno prema Schönen, 2014.)

Igra je pojam koji zahtijeva aktivnost koja ne mora nužno biti zabavna. Igra je definirana pravilima, kompetitivnošću te željom za postizanjem nekog specifičnog cilja. Svaka igra prema Versteeg (2013.) mogla bi imati tri osnovna elementa, a to su **bodovi, bedževi i lista poretka**. Ta tri elementa poznata su i pod nazivom PBL sustav (eng. *Point, Badge, Leaderboard system*), gdje se bodovima opisuje mjerljiva aktivnost, bedževima vizualno prikazuje određeno postignuće i priznanje korisniku, a lista poretka služi za međusobnu usporedbu sudionika sustava (Versteeg, 2013.; Lombriser, 2015.; Werbach, 2012.). Lombriser (2015.) proširuje PBL sustav te navodi da, kako bi nešto bilo igra, mora imati sljedećih šest komponenata: (1) **pravila**, (2) **varijable** i **jasan ishod** igranja, (3) **poredak** ovisno o uspjehu, (4) **izazov**, tj. težinu koja varira ovisno o napredovanju, (5) svojstvo **poistovjećivanja** s dijelovima igre te (6) **poveznice sa stvarnošću**. Sæter i Valle (2013.) naglašavaju kako bi svaka igra svoje igrače trebala privući na **dobrovoljan** način te ih, kada su jednom u sustavu, zadržati što je duže moguće.

Hakulinen (2015.) navodi da ozbiljne igre najveću primjenu imaju u obrazovnim sustavima, gdje su primjeri vidljivi u **vojnim simulatorima** te u **području zdravstva, umjetnosti i sporta**. Fitz-Walter (2015.) tvrdi kako se ozbiljne igre temelje na cjelokupnoj igri koja kao cilj ima educiranje korisnika, za razliku od gemificirane alternative koja ima isti cilj, no koristi samo odabrane elemente računalne igre. Igra kao pojam sadrži niz elemenata te zato spada u kompozitnu kategoriju u kojoj se nalazi niz poveznica, međuodnosa i pravila koja mogu biti pronađena i izvan same igre. Igre osiguravaju trenutnu povratnu informaciju o tome što se u sustavu događa i što igrač svojim aktivnostima radi, bez obzira na to jesu li odigrane akcije uspješne ili ne. Versteeg (2013.) ističe kako su **igre zabavne** jer zadovoljavaju **potrebe** korisnika za postizanjem određenog **iskustva** i uključuju aktivnosti koje mogu djelovati motivirajuće na korisnika. Schönen (2014.) dodaje kako je u svakom trenutku moguće znati status **napretka** unutar razine, kao i opisati trenutno stanje unutar igre. Igra s vremenom i napretkom **povećava** svoju **težinu** u skladu s vještinama koje je igrač tijekom igranja svladao (Schönen, 2014.). Ako je gradiranje težine pravilno raspoređeno, igrač ima pozitivan osjećaj prema izazovima, čime se postiže i veća razina ugone. Schönen (2014.) navodi kako se opisani pojam odnosi na emotivni put i zadovoljstvo igranja, poznatiji pod nazivom *tijek* (eng. *Flow*). Evidentno je kako u slučaju dodavanja dodatnog ili novog neformalnog pravila gemificirana aplikacija može postati igrom. Zato se postavlja pitanje koji su elementi računalnih igara koji bi se mogli koristiti unutar *gemificiranih* aplikacija. Ludvigsen i Wallervand (2012.) zaključuju kako gotovo svaki element koji je pronađen unutar igre može biti dio *gemificiranog* sustava.

Gemifikaciju se kao pojam ne bi trebalo povezivati uz **određeni sadržaj, svrhu** ili **scenarij**. Prilikom planiranja izrade gemifikacijske aplikacije trebaju se razmotriti i elementi pomoću kojih su računalne igre dizajnirane:

- a) grafičko sučelje, bedževi, nivoi i ljestvice poretka,
- b) ponavljajući mehanizmi igara,
- c) smjernice za rješavanje problema i bodovanje rješenja,
- d) konceptualni model koji se veže uz priču, znatiželju, elemente fantazije,
- e) metoda oko koje se igra gradi.

Schönen (2014.) navodi da gemifikacija nije igra namijenjena jednom cilju, već je *gemificirani* sustav prekriven motivacijskim aktivnostima i svojstvima vidljivim u računalnim igrama, a koji potiču želju za **komunikacijom, suradnjom i dijeljenjem informacija** kako bi se ostvarili **ciljevi**.

Motivacijska svojstva mogu se promatrati ovisno o intrinzičnoj ili ekstrinzičnoj motivaciji korisnika. Važno je da su korisnici *gemificiranog* sustava **svjesni svojih obveza**, ali isto tako i **mogućnosti** koje su im na raspolaganju glede **autonomije**. Versteeg (2013.) i von Schiller (2015.) navode kako je visok stupanj autonomije povezan s **teorijom samoodređivanja** (eng. *self-determination theory*) te je uz kompetenciju i povezanost s drugim sudionicima preduvjet za **zadovoljstvo** i povećane **performanse korisnika**. Prema Versteegu (2013.) i Lombriseru (2015.), teorija samoodređivanja važna je za motiviranje studenata, a u njoj se ističe kako je intrinzična motivacija efikasnija od ekstrinzične i vanjskih poticaja. Singer (2013.) i Hakulinen (2015.) tvrde kako se intrinzična motivacija temelji na trima osnovnim **psihološkim potrebama**, a to su **kompetentnost**, **povezanost** sa sudionicima i **autonomija** u vlastitim odlukama i ponašanju.

Lombriser (2015.) navodi da gemifikacija može poprimiti nekoliko oblika, od jednostavnog korištenja mehanika računalnih igara kao dodatka postojećim sustavima, pa sve do potpune integracije produktivnih zadataka i virtualnih okruženja. Primarni cilj je **promjena ponašanja**, poticanje **motivacije** i **razvoj vještina** kod ciljane skupine kroz posebno osmišljene zadatke. Korisnici se trebaju poznavati, ciljevi sustava trebaju se poistovjetiti s ciljevima korisnika te se ciljevi trebaju razložiti na moguća postignuća, društvenost i otkrivanje. Navedena tri elementa predstavljaju faktore koji direktno utječu na motivaciju korisnika.

Schönen (2014.) ističe kako računalne igre, ako su pomno kreirane i osmišljene, sadrže ciljeve, bilo da su kratkoročni ili dugoročni, koji bi trebali biti specifični, mjerljivi, dostizni, realistični i vremenski ograničeni. Jednostavan prijelaz i implementacija elemenata računalnih igara u radno okruženje koje nije vezano za igru poprilično je kompleksno i nije uvijek moguće. Igre se baziraju na emociji, intenzitetu i dugoročnosti, za razliku od okruženja koja nisu igre gdje se aktivnosti svode na zadatke, produktivnost i brzinu.

Gemificirana aplikacija ili sustav posjeduje sljedeća obilježja (prema Fitz-Walter, 2015.):

- Strukturirana i specifična **pravila** kroz koja se potiče osjećaj zabave.
- Niz **elemenata računalnih igara** koji su dio sustava s ciljem stvaranja osjećaja igranja.
- **Percepciju** sustava kao **igre**, ali i kao **alata za motiviranje** korisnika.
- **Promjena u ponašanju**, gdje je "ozbiljnost" prioritet u odnosu na "zabavu".

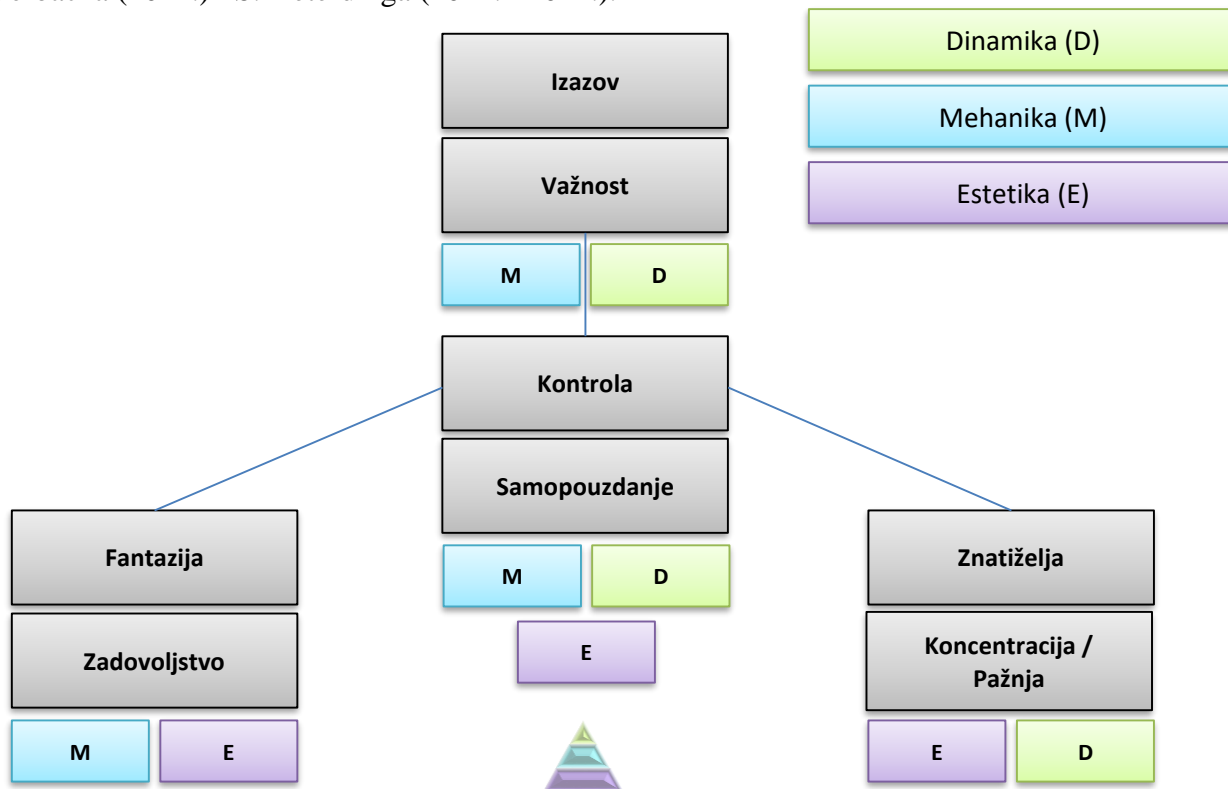
3.2 ELEMENTI I STRUKTURA GEMIFIKACIJSKOG PRISTUPA

U ovom poglavlju navode se autori i istraživanja iz područja gemifikacije, te razmatranja i teoretski opisi gemifikacijskih sustava. Prikazani su koncepti i elementi računalnih igara, s posebnim naglaskom na mehaniku i dinamiku. Poglavlje se zaključuje načinima prema kojima se *gemificirani* sustav može dizajnirati.

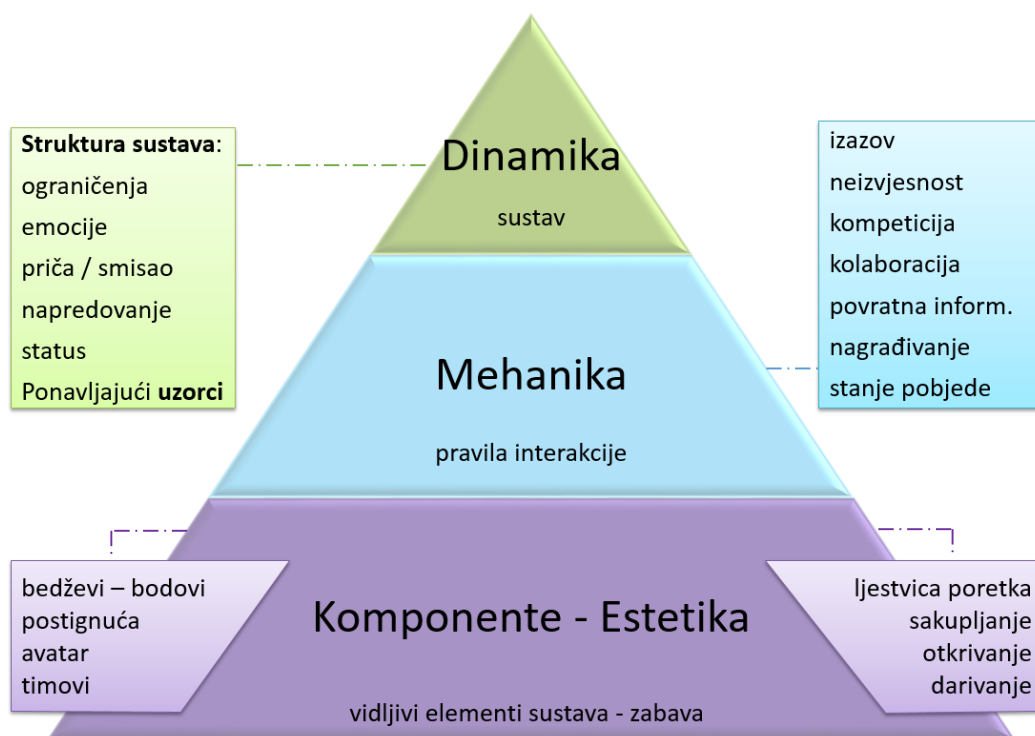
Elementi računalnih igara predstavljaju dijelove igre koji doprinose igračkom iskustvu ako su pravilno povezani. Kako bi obrazovna igra bila zabavna, autori Malone i Lepper (1987.) navode četiri elementa koji predstavljaju podlogu gemifikacijskog pristupa: **izazov**, **znatiželja**, **fantazija** i **kontrola**. Istraživanje Deterdinga i suradnika (2011.) gemifikaciju opisuju na temelju triju koncepata, **mehanika**, **dinamika** i **estetika** (eng. *MDA*, *Mechanics*, *Dynamics*, *Aesthetics*), koji su potpomognuti korisniku vidljivim elementima, tj. komponentama računalnih igara. **Mehanika (M)** predstavljena je pravilima sustava, **dinamika (D)** interakcijom i ponašanjem sustava, a **estetika (E)** zabavom i zabavnim elementima sustava. Navedeno potvrđuju i ostali autori, poput Zichermanna i Cunninghama (2011.) te van den Berga (2014.). Obje podjele imaju dodirne točke te se mogu prikazati unutar istog grafičkog prikaza, što je vidljivo u nastavku rada na slici 16.

Hamari i suradnici (2014.) navode sljedeće elemente koji se pojavljuju u gemificiranom pristupu: **bodovi**, **top-lista postignuća**, **bedževi**, **razine**, **vizualni prikaz napretka** u sustavu, **pokazatelj uspješnosti** korisnika, motivirajuća *priča*, *jasni ciljevi*, *povratna informacija*, *sustav nagrađivanja*, *avatar*, *usputni izazovi* i *dinamični razvoj korisničkog profila*. Navedena podjela temeljena je na preglednom radu koji obuhvaća 24 empirijska istraživanja od ukupno pronađeno 716 istraživačkih radova na temu gemifikacije u obrazovanju. Navedenu podjelu koriste **Zichermann** i **Cunningham** (2011.), **Werbach** i **Hunter** (2012.), **Sailer** i **suradnici** (2013.) te **Cavaco** i **suradnici** (2015.). **González-González** (2013.) proširuje navedenu podjelu s **kolektivnošću** kao osobinom koja motivira ljude za skupljanje određenih elemenata. **El-Khuffash** (2015.) unutar svog istraživanja koje obuhvaća **79 gemificiranih** sustava navodi kako 84% sustava koristi **bodove** kao jedan od najkorištenijih elemenata računalnih igara. **Izazovi**, **bedževi**, **liste napretka**, **nagrade**, **natjecanja** i **suradnja** ostali su elementi koji su vidljivi u istraživanju. 51% sustava pokušava **unaprijediti motivaciju** korisnika. 88% *gemificiranih* sustava **besplatno** je za korisnike, a 74% sustava bazirano je na **web tehnologijama**. Od 79 navedenih sustava većina je usmjerena na zdravlje i povezane teme.

U literaturi je zastupljena i tvrdnja da se računalne igre temelje na četiri jednako važne komponente, a to su **tehnologija**, **estetika**, **mehanika** i **priča** (von Schiller, 2015.). Struktura gemifikacijskog pristupa koja se prikazuje na slikama 16. i 17. rađena je prema uputama K. Werbacha (2012.) i S. Deterdinga (2011. i 2012.).



Slika 16. Osnovni elementi gemifikacijskog pristupa (izvor: autor disertacije)



Slika 17. Struktura gemifikacijskog pristupa (prilagođeno prema Werbach, 2012.)

3.2.1. Elementi gemifikacije - mehanika i estetika računalnih igara

Mehanika računalnih igara predstavlja pojam koji opisuje sustav baziran na pravilima za vođenje i poticanje korisnika na istraživanje i učenje pomoću mehanizama povratnih informacija. Mehanika i estetika računalnih igara mogu služiti kao poveznice ili elementi koji se uključuju u klasičan sustav koji nije igra. Kada se usklade sa željama i očekivanjima korisnika, **mogu utjecati na korisničko iskustvo i intrinzičnu motivaciju**. Najčešći elementi koji se pojavljuju u poslovnim i obrazovnim sustavima jesu **nagradni simboli, statusi**, osobna i javna **postignuća**, ali i drugi koji se navode u tablici 19. Za pravilno korištenje i razumijevanje mehanike računalnih igara potrebno je upoznati se s tehnološkim mogućnostima obrazovne platforme, znati kako navedena mehanika radi i kada se određeno rješenje može koristiti radi utjecanja na razmišljanje i motiviranje korisnika sustava. Zbog povezanosti s tehnološkim razvojem, mehanički elementi **mijenjaju se i prilagođavaju** novim trendovima te načinima pomoću kojih se korisnika može motivirati. Prema Mayu (2007.), mehanika računalnih igara u obrazovnim sustavima treba osigurati nekoliko osobina/pojava kao što su:

- **Eksperimentalno učenje:** dobrovoljan odabir aktivnosti koje se provode duži vremenski period, rezultira određenim pomakom u znanju.
- **Učenje kroz istraživanje:** poticanje korisnikove mašte kao npr.: "Što se dogodi kada se zadovolji ili napravi određena akcija?"
- **Samo učinkovitost:** poticanje korisnika da bude u sustavu što je duže moguće, jer što se duže određena aktivnost ponavlja to će se prije i usavršiti.
- **Jasno i precizno opisani cilj:** gdje je učenje učinkovitije i sam proces jasniji.
- **Kooperacija:** timski rad usmjeren zajedničkom rješavanju određenog zadatka.
- **Povratna informacija:** učestali i brzi rezultati svega što korisnik u sustavu radi.

Prema istraživačima Nielsonu (2013.) i Schonfeldu (2010.) u tablici 19. navode se 24 najčešća tipa **gemifikacijskih mehanizama** koji su trenutno prepoznati i prihvaćeni u praksi. Svaki od njih može se kategorizirati prema trima atributima: mehanici igre, beneficijama i osobnosti. Mehanika igre može se podijeliti na ponašanje, povratnu informaciju i napredovanje, a osobnost, prema podjeli Bartlea (1985. i 1996.), na pobjednika, društvenjaka, sakupljača i istraživača, što predstavlja i osnovnu podjelu tipova korisnika ili igrača.

Tablica 19. Elementi mehanike i estetike u gemifikacijskom sustavu
(sastavio: autor disertacije prema Nielsonu (2013.) i Schonfeldu (2010.))

Postignuća	Bonusi	Odbrojavanje	Beskonačno trajanje igre	Vlasništvo	Redovito Nagrađivanje
Obveze / Izazovi	Upoznavanje informacijama	Neizvjesnost / Otkrivanje	Razine	Bodovi	Status
Bihevioralni Momentum	"Kombo" efekt x3	Epsko značenje	Gubitak averzije	Napredovanje	Optimizam
Produktivnost	Zajednička kolaboracija	Iznenadenje	Svjestan rizik	Zadaci i izazovi	"Ovisnost" / Predanost igri

Mehanizmi i komponente računalnih igara, navedeni u tablici 19., nisu novi. Nova je jedino računalna i informacijsko-komunikacijska tehnologija koja podržava njihovu efikasniju i vizualno privlačnu primjenu. Ipak treba istaknuti da **svi elementi računalnih igara nisu primjereni za sve tipove igrača**. Svi elementi koji se mogu pronaći u računalnim igrama svoju primjenu mogu pronaći u poslovnim ili obrazovnim sustavima, ali neće biti iste važnosti.

3.2.2. Elementi gemifikacije - dinamika računalnih igara

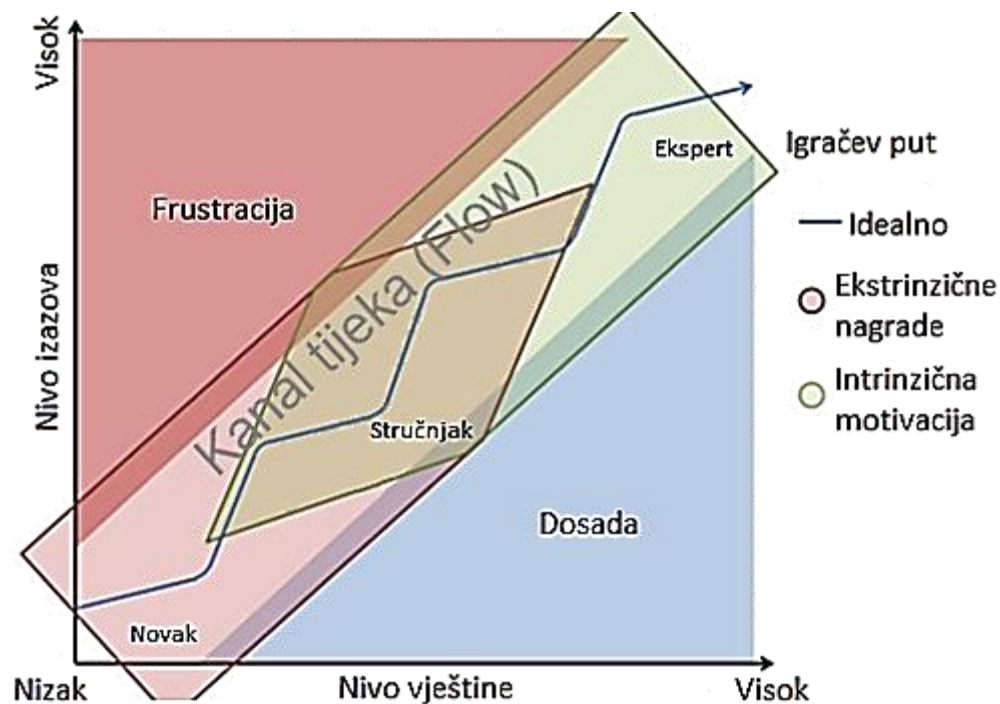
Dinamika je međusobno povezana s mehanikom računalnih igara unutar sustava kroz sve aktivnosti u kojima korisnik može sudjelovati.

"Dinamika računalnih igara predstavlja uzorak ponavljanja za igru i igrača radi stvaranja ugodnog osjećaja prilikom korištenja sustava." (Wu, 2011.)

Wu (2011.) navodi kako su bodovi, bedževi, ljestvice poretka i drugi elementi mehanike računalnih igara osmišljeni radi utjecanja na motivaciju i ponašanje korisnika. S druge strane, postoji propisano vrijeme i trenutak kada se u sustavu pojave ili otključaju do nedavno igraču nedostižni elementi, dodijele nagrade za postignuće i sl. pod utjecajem aktivnosti korisnika. **Dinamika računalnih igara čini kombinaciju raznih mehaničkih elemenata** (iz tablice 19.) u odnosu **na** vrijeme provedeno u učenju radi stvaranja **interesantnog** i **zabavnog** ambijenta u kojemu se korisnik nalazi prilikom korištenja *gemificiranog* sustava.

Kim (2011.) prikazuje primjer u kojem se može navesti korisnička razina stručnosti, gdje postoje (III) **novak**, (II) **stručnjak** i (I) **ekspert**, kao što je prikazano na slici 18. Svakoj razini pristupa se s drugog stajališta, gdje je učeniku/igraču koji je u statusu **novaka** potrebno objasniti način korištenja sustava, način napredovanja i postizanja određenog cilja.

Učeniku/igraču koji je u statusu **stručnjaka** naglasak se stavlja na nove elemente sustava, aktivnosti i izazove, dok se **ekspertu** naglasak stavlja na prepoznavanje i utjecanje na sustav i druge korisnike (Kim, 2011.). Balans između izazova i vještine korisnika važan je aspekt koji se povezuje s teorijom tijeka (eng. *flow theory*), o kojoj se govori u poglavlju 3.4.



Slika 18. Zona tijeka i igračev put (prilagođeno prema Schönen, 2014.)

S obzirom na to kako gemifikacija spada u još uvijek nedovoljno opisana i istražena područja društvenih znanosti, ne postoji mnogo utemeljenih teorija kojima bi se nastavnici ili administratori *gemificiranih* sustava trebali voditi. U nastavku poglavlja navode se dvije najpoznatije teorije prema kojima se *gemificirani* sustav može dizajnirati.

Prvi pristup (ili teorija) temeljen je na *dizajnu sustava oko korisnika*, a utemeljili su ga i opisali Mario **Herger** i Janaki **Kumar** (2013.) u svojoj knjizi: "*Gamification at Work: Designing Engaging Business Software*". Predloženi dizajn sastoji se od nekoliko koraka, a prvi je **razumijevanje studenata i ishoda učenja** tj. ciljeva koji se žele postići raznim aktivnostima ili misijama. Slijedi **istraživanje psiholoških elemenata koji utječu na motivaciju** korisnika, a u tu svrhu koristi se mehanika računalnih igara. U posljednjem koraku potrebno je pažljivo **promatrati** uključenu mehaniku te **mjeriti rezultate studenata**.

Schönen (2014.) dodaje kako je cilj navedenih koraka dobiti povratnu informaciju o tome što utječe na korisnike i kako postići osjećaj zanesenosti. **Herger** i **Kumar** (2013.) podsjećaju kako se uz navedeno treba planirati i zabavni smisao prilikom boravka u sustavu.

Drugi pristup, koji se odnosi na dizajn *gemificiranih* sustava, utemeljio je Kevin **Werbach** (2012.), a detaljno ga je opisao u svojoj knjizi "*For the Win: How Game Thinking Can Revolutionize Your Business*" u šest međusobno povezanih koraka. Model koji je predložio zove se **6D model**. On uključuje šest riječi s prvim slovom **D** te otuda i naziv.

1. Osmisliti ciljeve i ishode sustave (eng. *define business objectives*)
2. Opisati željena ponašanja (eng. *delineate target behaviors*)
3. Opisati korisnike sustava, igrače (eng. *describe your players*)
4. Osmisliti ponavljajuće aktivnosti (eng. *devise activity loops*)
5. Osmisliti elemente zabave (eng. *don't forget the fun*)
6. Osigurati potrebne tehnološke preduvjete (eng. *deploy appropriate tools*)

Navedeni gemifikacijski model uključuje komponentu *emocije* koja je zasnovana na zabavi, igri i korisničkom iskustvu, kao i održivom sustavu u kojem je rezultat i aktivnost korisnika mjerljiv, a sve to radi postizanja unaprijed zadanih ciljeva. Schönen (2014.) dodaje da se cjelokupan 6D model sastoji od smjernica kako koristiti suvremena tehnološka postignuća (elemente računalnih igara) u specifičnim situacijama. Schönen ističe da se do uspjeha može doći samo uz ispravan odabir i primjenu elemenata računalnih igara, objašnjavajući kako je prvih pet elemenata predloženog Werbachovog 6D modela sačinjeno od **planiranja** aktivnosti i **opisivanja** ciljane skupine ispitanika.

3.3. TIPOVI IGRAČA

U ovom poglavlju navode se istraživanja i zaključci o korisnicima te njihovom ponašanju za vrijeme igranja računalnih igara. Navode se moguće podjele, prema kojima se rade i osnovne grupacije među korisnicima. Svaka skupina opisana je i stavljena u grafički međuodnos u nastavku rada.

Prilikom implementacije elemenata računalnih igara u sustav koji nije računalna igra dobro je **o korisnicima** razmišljati kao **o igračima**. Jedan od najvažnijih aspekata uspješne primjene gemifikacije uključuje istraživanje i razumijevanje onoga što motivira korisnike sustava. Korisnici su različiti, dolaze iz različitih okruženja, smatraju zabavnim razne situacije te je zato potrebno razumjeti da sve gemifikacijske tehnike nisu jednako zastupljene ni prihvaćene kod svih igrača. Richard Bartle prvi je 1978. godine klasificirao tipove igrača proučavajući tip *online igre* pod nazivom MUD (eng. *Multi User Dungeon*). Njegova podjela i tipologija igrača navedena je u nastavku rada te se i danas se koristi prilikom dizajniranja interaktivnih sustava.

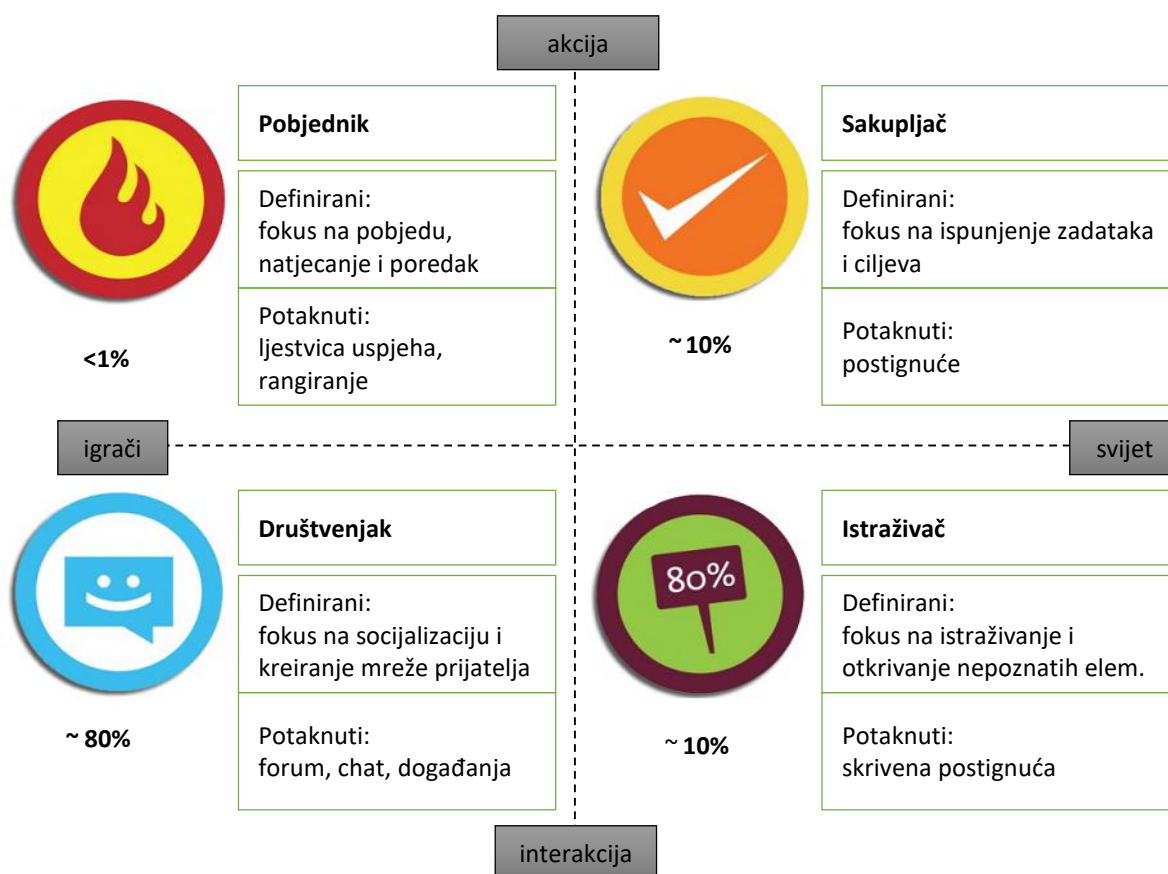
Sakupljač (eng. *achiever*) – sakupljač je tip igrača koji je **motiviran** nekim oblikom **sakupljanja** nagrada iz sustava. Nagrade mogu biti u obliku bodova, bedževa, napredovanja ili sl. Rasmussen (2014.) ističe kako cilj ovog tipa igrača **nije uvjetovan drugim igračima** i njihovim mišljenjima. Motivira ga rješavanje zadataka, sakupljanje što je više moguće bodova i napredovanje na top-ljestvici. **Nagrade zadržava za sebe** bez potrebe je za pokazivanjem vlastitih postignuća. Bartle sugerira da **10-ak posto** igrača pripada upravo ovoj skupini (Schönen, 2014.; de Vitte i suradnici, 2015.; Gil i Cantador, 2015.).

Istraživač (eng. *explorer*) – istraživač **želi pronaći** sve što se nalazi unutar sustava. Želi pronaći i znati sve što se može pronaći i otkriti. Rasmussen (2014.) govori da je ovaj tip igrača motiviran **skrivenim elementima** koji se postepeno pronalaze ili otkrivaju. Igrač može bez osjećaja zamora **ponoviti** neku radnju ili aktivnost **više puta** radi prolaska na drugu razinu ili otkrivanja određenog elementa sustava. Bartle sugerira da **10-ak posto** igrača pripada ovoj skupini (de Vitte i suradnici, 2015.; Gil i Cantador, 2015.).

Društvenjak (eng. *socializer*) – društvenjak je motiviran **interakcijom** s ostalim igračima, a ne samim sustavom. Bartle sugerira kako većina, gotovo **80-ak posto** igrača, pripada upravo ovoj skupini. Rasmussen (2014.) ističe da je ishodište motivacije ovog tipa igrača u **komunikaciji** s ljudima, **pomaganju** i **stvaranju odnosa** kroz sustav (Vitte i suradnici, 2015.; Gil i Cantador, 2015.).

Pobjednik (eng. *killer*) – pobjednik je motiviran **nagradama** i **bodovima**, kao i sakupljač, no glavna razlika je u tome što **pobjednik uživa u pobjeđivanju** drugih igrača (Schönen, 2014.; de Vitte i suradnici, 2015.; Gil i Cantador, 2015.). Rasmussen (2014.) navodi kako se pobjednik voli **nametati** tamo gdje društvenjak pomaže i stvara pozitivno iskustvo. Pobjednik potencira suprotno, negativno iskustvo u drugim sudionicima. Preferira **javna nadmetanja** i **top-liste postignuća**. Bartle sugerira da manje od **1 posto** igrača pripada ovoj skupini.

Osim navedenih tipova igrača, prema Bartleu (1978.), postoje i druge podjele koje se mogu razmatrati, no važno je napomenuti kako igrači **rijetko** pripadaju **samo jednoj grupi** igrača. Igrači najčešće posjeduju osobine svih četiriju tipova igrača i taj je element razvijen do neke mjere. Na slici 19. navodi se, prema Bartleu (1996.) i Ragupathiju (2012.), odnos između navedenih tipova igrača.



Slika 19. Tipovi igrača i ikone kojima igrači mogu biti označeni u računalnim igrama (izvor: autor disertacije prema Bartle, 1996. i Ragupathi, 2012.)

Podjelu Richarda Bartlea dodatno je proučavao Andrzej Marczewski (2013.) i proširio ju je nekim napomenama. Bartleov model napravljen je na temelju **MUD igara** (eng. *Multi User Dungeon*) ili, u današnjem trenutku, igara **MMO** (eng. *Massively Multiplayer Online*). Svi korisnici tj. igrači su u sustavu radi užitka igranja. Ako se sustav **pogrešno dizajnira**, igrači neće biti zadovoljni te neće biti osigurana **teorija tijeka** (eng. *flow theory*). De Vitte i suradnici (2015.), kao i Gil i Cantador (2015.), prihvaćaju obje podjele te na njima grade svoja istraživanja. Proširena podjela igrača temelji se na **modelu RAMP** (eng. *Relatedness, Autonomy, Mastery, Purpose*)¹, koji za podlogu koristi intrinzičnu motivaciju (Marczewski, 2013.) te glasi:

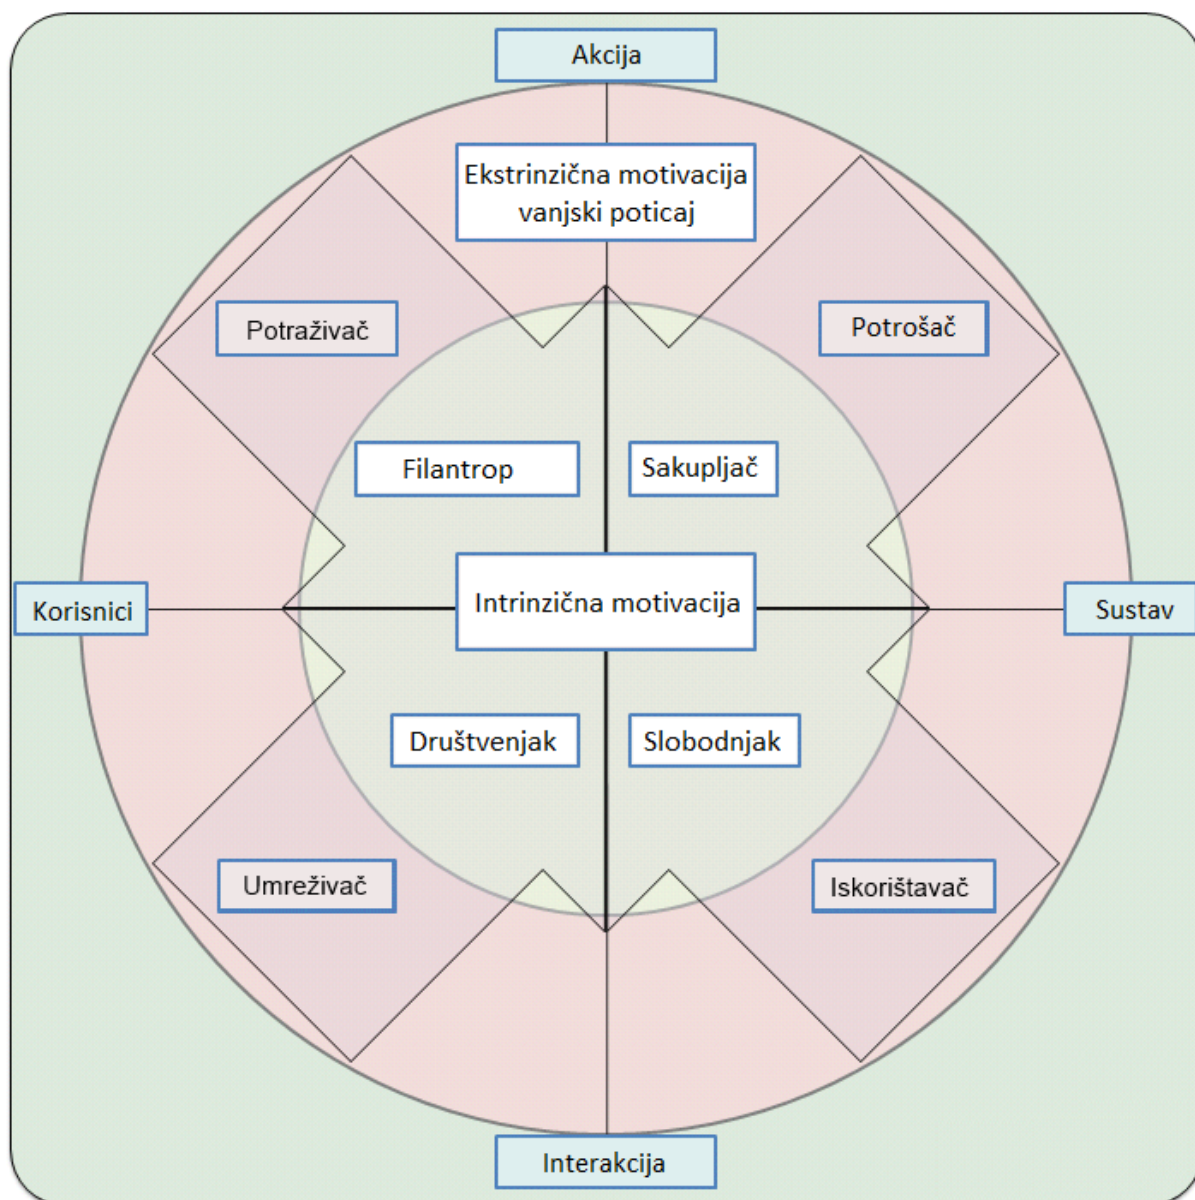
- | | |
|---|---|
| 1. Društvenjak (eng. Socialiser) | 3. Slobodnjak (eng. Free spirit) |
| 2. Sakupljač (eng. Achiever) | 4. Filantrop (eng. Philanthropist) |

Marczewski (2013.; 2016.) ističe da je **društvenjak** motiviran povezanošću s ostalim sudionicima sustava. **Slobodnjak** je igrač koji preferira slobodu, autonomiju unutar sustava. Voli istraživati i kreirati nove elemente ovisno o mogućnostima sustava. **Sakupljač** je motiviran usavršavanjem vještine i znanja. Želi steći nova znanja i usavršiti ih te testirati naučeno pomoću raznih zadataka i prepreka. **Filantrop** je motiviran svrhom pomaganja drugim pojedincima ili grupi radi uljepšavanja boravka igračima u sustavu. Iz navedene podjele vidljivo je da neki tipovi igrača nedostaju, a to su igrači koji igraju igru ili koriste sustav samo zbog vanjskog poticaja. Takav će igrač sakupljati bodove i tražiti nagrade za svoju aktivnost te je iz navedenog razloga prisutna još jedna podjela igrača u nastavku teksta:

- | | |
|---|---|
| 5. Umreživač (eng. Networker) | 7. Potrošač (eng. Consumer) |
| 6. Iskorištavač (eng. Exploiter) | 8. Potraživač (eng. Self seeker) |

Umreživač je tip korisnika koji će se povezati s ostalim korisnicima samo zbog broja umrežavanja i nagrade koja bi mogla uslijediti. Iskorištavač je tip korisnika koji želi nagradu pod svaku cijenu jer koristi sustav. Navedeni korisnik sposoban je pronaći pogreške u pravilima sustava te ih zlorabiti za dobivanje određene nagrade ili postignuća. Potrošač želi nagradu za svoje aktivnosti u sustavu. Potrošač će rješavati zadatke, kvizove, a čak će i naučiti ako mu se obeća nagrada u sustavu. Potraživač želi nagradu za svoje aktivnosti koje su vezane uz ostale korisnike te će odgovoriti na pitanja kako bi dobio bodove bez obzira na kvalitetu. Kvantiteta mu je prioritet. Kada se svih osam tipova igrača stavi u međuodnos, dobiva se slika 20. koja je navedena u nastavku ovog doktorskog rada.

¹ Relatedness = povezanost, Autonomy = autonomija, Mastery = vještina, Purpose = svrha



Slika 20. Odnosi između igrača – proširena podjela (prilagođeno prema Marczewski, 2013.)

Slika slike 20., stavlja u odnos **korisnike** i **sustav**, kao i **interakciju** i **akcije**. Navedeni elementi prikazani su kroz **intrinzičnu** i **ekstrinzičnu** motivaciju s obzirom na to da su obje motivacije gotovo uvijek prisutne u obrazovnim sustavima. Prikazani međudnos služi administratoru, dizajneru sustava te nastavnicima kako bi shvatili kompleksnost ljudskog ponašanja i promišljanja. Svaki polaznik unutar grupe posjeduje nekoliko karakteristika igrača, što optimizaciju sustava čini velikim izazovom. Težina i raznolikost zadataka te motivirajući elementi sustava trebaju biti pažljivo odabrani ako se želi postići optimalan ishod i obrazovna izvrsnost.

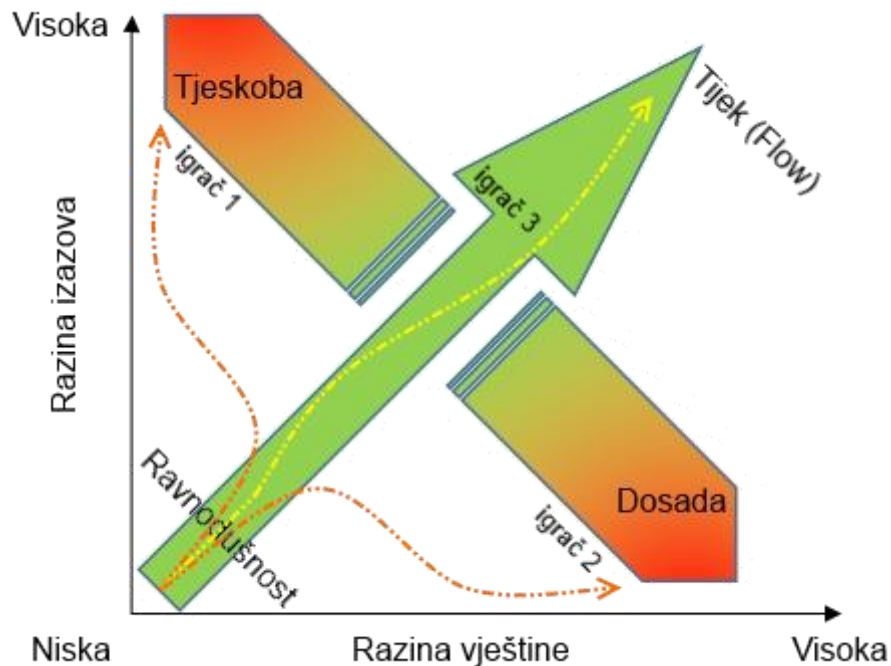
3.4. TEORIJA TIJEKA

U ovom poglavlju opisuje se *teorija tijeka* autora Mihalyja Csikszentmihalyija (1989.; 2002.) (eng. *flow theory*) te njena primjena u gamificiranom dizajnu. Navode se istraživanja mnogih autora i njihovo viđenje predložene teorije i pozitivne psihologije. Poglavlje završava smjernicama koje je nužno zadovoljiti kako bi se postiglo iskustvo tijeka.

Računalne igre gotovo uvijek povećavaju težinu kad igrač prolazi kroz igru kako bi se balansirao izazov u odnosu na vještinu igrača. Schöner (2014.) navodi da je jedan od razloga zašto su igre **zabavne** taj što igre konstantno predstavljaju **određeni izazov** za igrača bez obzira na stupanj završenosti razine. Izazovi su često savladivi u nekom razumnom vremenu igranja. Navedeno se razmatra i prilikom kreiranja *gamificiranog* sustava koji uključuje elemente računalnih igara. Potrebno je balansirati izazove koji se stavljaju pred korisnika i njegov napredak. Psiholog i istraživač Mihaly Csikszentmihalyi (1989.; 2002.) opisao je stanje kod kojeg pojedinac **potpuno kontrolira** svoje aktivnosti vezane uz vještine i izazove. Csikszentmihalyi (1989.; 2002.) je razvio svoju teoriju prilikom istraživanja razlika između intrinzične i ekstrinzične motivacije te postizanja **optimalnog stanja uma**. Versteeg (2013.), Vehns (2014.), von Schiller (2015.), ali i mnogi drugi, uvažavaju opisano stanje i teoriju koju je Csikszentmihalyi utemeljio 1975. godine pod nazivom "**Teorija tijeka**" (eng. *Flow theory*). Navedena teorija detaljno je opisana u njegovoj knjizi: "*Beyond Boredom and Anxiety*". Von Schiller (2015.) dodaje kako je istraživanje temeljeno na osjećaju koji pojedinci imaju prilikom aktivnosti koje su **odabrali sami i svjesno**. Versteeg (2013.) se slaže s time da su iskustvo i osjećaj zabave subjektivni i ovise o osobnim stavovima korisnika sustava. Versteeg (2013.) ističe kako se administrator, nastavnik i/ili dizajner treba orijentirati na omogućavanje korisnicima maksimalne slobode kako bi uspjeli postići **autonomiju i osjećaj zabave** unutar sustava koji je ipak baziran na unaprijed definiranim pravilima.

Prema Schöneru (2014.), zona tijeka nalazi se između **zone tjeskobe** i **zone dosade**, gdje je vidljivo da, ako se stanje pojedinca nalazi iznad stanja zanesenosti, **razina vještina** neće dostići **razinu izazova** i kao rezultat pojavit će se **tjeskoba** (vidjeti sliku 21.). Obrnuta situacija vidljiva je u slučaju kada nastupa stanje **dosade**. Bitno je ispravno percipirati **izazove** i **potrebne vještine**, dok su ciljevi u ovom slučaju sporedni. Slučaj u kojem pojedinac **ne uspije u rješavanju problemskog zadatka poželjan je**, jer se stvara **iskustvo vježbanja i svladavanja prepreke**. Schöner zaključuje da isto vrijedi i za izazove, koji bi se trebali mijenjati kako se mijenja razina korisničkog iskustva, čime se osigurava da izazov nije **prelagan ili pretežak**.

Csikszentmihalyi navodi da igrač, kad je u stanju tijeka, postiže **maksimalan učinak**, koji je popraćen **osjećajem ugone i opuštenosti**, što von Schiller (2015.) i Vehns (2014.) potvrđuju i u svojim istraživanjima. Rajić (2011.) navodi: "Očaravajuća zanesenost kod korisnika često se opisuje kao stanje optimalnog iskustva, duboke koncentracije i osjećaja ugone". Navedena izjava (Rajić, 2011.) opisuje stanje tijeka koje je prikazano na slikama 21. i 22.



Slika 21. Prikaz stanja tijeka (izvor: autor disertacije prema Rajić, 2011.)

Slika 21. ilustrira tri ekstremno različita puta koje igrači mogu doživjeti. Intrinzična motivacija zajedno sa sustavom definira tijek koji igrač može osjetiti. Svi igrači kreću s igrom u istom trenutku s pretpostavkom da im je sustav **jednako zanimljiv**. Igrač 1 i igrač 2 koji su prikazani na slici 21., relativno **brzo gube koncentraciju**, motivacija se gubi i upadaju u situaciju u kojoj je teško biti produktivan i fokusiran na ciljeve. Oba igrača doživljavaju zasićenje. **Odustajanje** od korištenja sustava i provođenje planiranih aktivnosti je **vjerojatno**. **Igrač 1** ne posjeduje potrebne vještine, tj. izazovi su mu preteški za svladavanje. Zadaci sustava su **preteški**, a time dolazi do stanja **tjeskobe**. **Igrač 2** posjeduje vještine koje su potrebne za rješavanje zadataka, ali ne vidi viši **smisao niti korist**. Zadaci sustava su **prelagani**, a time se dolazi do stanja **dosade**. **Igrač 3** uspijeva zadržavati koncentraciju i motivaciju za korištenje sustava. Početni izazovi dovoljno su teški da bi ih igrač mogao svladati. Slijedi **usavršavanje vještina**, što motivira korisnika za ponovni pokušaj i još **uspješnije** svladavanjem **izazova**.

Ranije je navedeno da se stanje igrača 3 teško postiže. Poželjno je imati manje grupe polaznika kojima je *gemificirani* sustav posebno prilagođen.

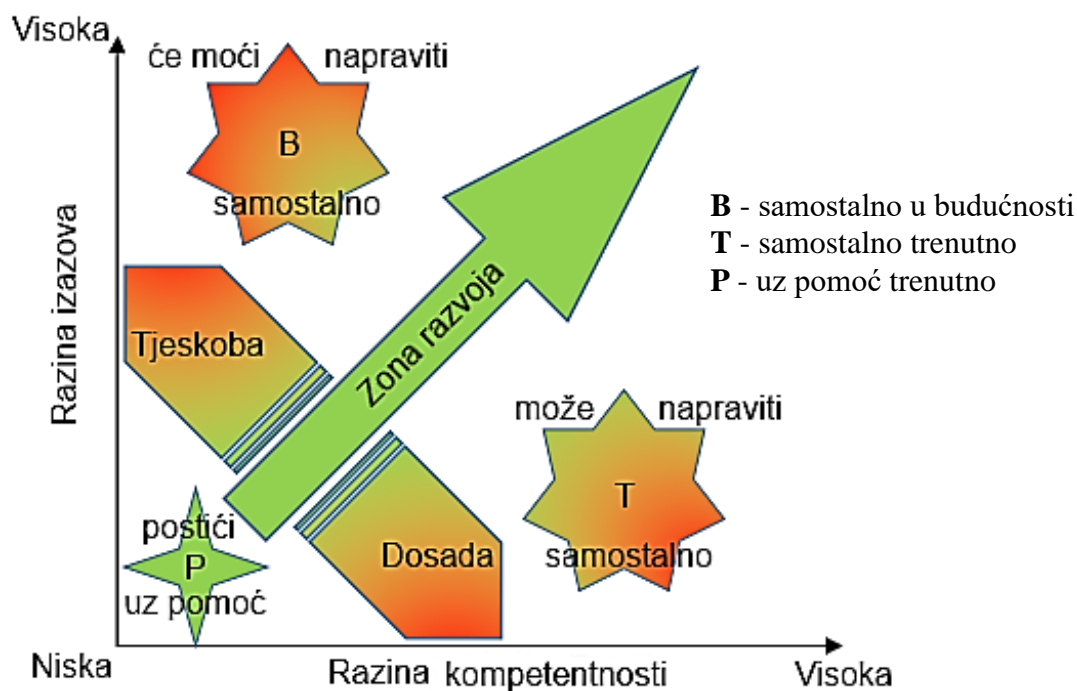
Igrač 3 u stanju tijeka najbrže prolazi kroz sustav uz najbolje rezultate. Ključni element u ovom slučaju je intrinzična motivacija, kod koje je pojedinac **ispunjen osjećajem zadovoljstva i ugone**. Istraživači (Rajić, 2011.; Versteeg, 2013.; Markova, 2013.) navode nekoliko osnovnih karakteristika koje je nužno zadovoljiti kako bi se postiglo iskustvo tijeka. Navedene karakteristike utemeljene su prema spoznajama Csikszentmihalyija i citiraju ih sljedeći autori (Rajić, 2011.; Versteeg, 2013.; Markova, 2013.):

1. **Dobrovoljno** rješavanje zadataka koji imaju jasne ciljeve i status završenosti.
2. Zadaci trebaju imati neposrednu **povratnu informaciju** o aktivnostima korisnika.
3. Zadaci moraju biti **izazovni i prilagođeni** postojećim vještinama korisnika.
4. Korisniku se treba omogućiti **osjećaj kontrole i autonomije**.
5. Zadatak treba održavati visoku **razinu koncentracije** kod korisnika.
6. **Postizanje gubitka svijesti** kod igrača uz potpuno predavanje aktivnostima sustava.
7. Iskrivljena percepcije **protoka vremena**, gdje aktivnosti djeluju izrazito kratko.

Csikszentmihalyi (1989.; 2002.) definira preduvjet za ulaz u stanje tijeka. Na prvom su mjestu **pravila i jasan cilj**, slijedi mogući **izazov** ili **mogućnost** koju korisnik može iskoristiti za povećanje vlastitih vještina te **povratna informacija** o aktivnostima igrača (von Schiller, 2015.).

3.5. PEDAGOŠKI ASPEKTI TEORIJE TIJEKA

Sustav školovanja koji je danas prisutan u obrazovnom sustavu baziran je na razredima i predmetima u osnovnoškolskom i srednjoškolskom obrazovanju te semestrima i kolegijima u visokoškolskom obrazovanju. Rajića (2011.) ističe kako je ovakav sustav prisutan već **350 godina**. S obzirom na ranije navedenih sedam karakteristika, jasno je da postoji jaz između iznesene **teorije i praktičnog stanja** u obrazovnom sustavu. Promatrajući slika stanja tijeka, uz manje korekcije može se prikazati i stanje razvoja znanja kod studenata, što je prikazano na slici 22 ove doktorske disertacije.



Slika 22. Prikaz zone razvoja studentskog znanja (izvor: autor disertacije prema Rajić, 2011.)

U zoni niske razine izazova i niske razine kompetentnosti nalazi se ono što student može postići uz **pomoć** nastavnika (P). U **zoni tjeskobe** nalazi se ono što će student moći samostalno učiniti **u budućnosti** (B). U **zoni dosade** nalazi se ono što student može **trenutno** (T) samostalno učiniti. **Zona razvoja** predstavlja optimalan put koji se nalazi između zone tjeskobe i zone dosade te ih u marginalnoj mjeri i uključuje.

Tradicionalni pristup obrazovanju temelji se na kontroli i fiksnim pravilima kao što su određeni raspored sati, mikro artikulacija nastavnog sata, socijalni odnosi hijerarhije, nametnuta socijalizacija unutar grupa, nastava usmjerena na predavača ili nastavnika, nepostojanje studentova izbora. **Suvremeni pristup** obrazovanju prihvaća navedene nedostatke, ali prikazuje i znatan pomak vezan uz autonomiju i potrebu pojedinca. **Uloga** nastavnika i studenta nije fiksno i kruto određena, postoji mogućnost preuzimanja uloga, a time i odgovornosti u slučaju da student poučava studenta. **Nastavna odjeljenja** znatno su smanjena, što omogućuje povezivanje sa sudionicima nastavnog procesa, stvara se poticajna okolina i prilika za zabavu. Dopuštena je **fleksibilna struktura** obrazovnog sustava koja se ne temelji na odrađenim satima i provjerama znanja. Rajić (2011.) navodi da je razvoj studentske samostalnosti, organizacijskih vještina i sposobnosti samostalnog, pravovaljanog i odgovornog donošenja odluka pozitivan ishod suvremenog pristupa obrazovanju i nužna je promjena u odnosu na tradicionalno obrazovanje. Uz teoriju tijekom koje je ranije objašnjena, tipovi igrača i elementi računalnih igara (mekanika, dinamika, estetika) predstavljaju **ključne elemente** koje gemifikacija koristi u svojoj teoriji i praksi.

3.6. UVOĐENJE MOTIVIRAJUĆIH ELEMENATA RAČUNALNIH IGARA U OBRAZOVNI SUSTAV

U ovom poglavlju navode se autori radova iz *gemificiranih* sustava za e-učenje, te njihova istraživanja koja su popraćena uočenim problemima i zaključcima. Navode se pozitivne smjernice za uključivanje elemenata računalnih igara u obrazovni sustav. Poglavlje završava usporedbom *gemificiranog* i tradicionalnog obrazovnog sustava uz poticaj za provođenje daljnjih istraživačkih aktivnosti.

Landers i Callan (2011.) istražuju tehnike za motiviranje studenata kroz razvoj obrazovne društvene mreže u trajanju od **jednog semestra**. U istraživanje je uključeno **385 studenta** koji su prihvatili pozivnicu poslanu elektroničkom poštom. Upoznavanje s ciljem i svrhom istraživanja provedeno je kroz peto-minutno predavanje.

Landers i Callan su u svoj sustav za e-učenje, osim nastavnih materijala, uključili mogućnost korištenja **profilne slike** i postavljanje javnih **objava** o vlastitim **postignućima**. Sustav podržava **asinkroni** način komunikacije, isto kao i dodjelu **bedževa** i **certifikata**.

Njihov sustav je sadržavao nekoliko provjera znanja s pitanjima zatvorenog tipa za čije odgovore su se dodjeljivali certifikati. Provjera znanja sadržavala je 10 pitanja za čije odgovore je student imao na raspolaganju 10 minuta. Pristup provjeri znanja bio je omogućen **svakih četiri dana**.

U njihovom pristupu posebno je zanimljiv **sustav mentoriranja** koji na temelju certifikata omogućuje uparivanje studenata s obzirom na individualna postignuća i potrebe za učenjem. Student koji ima poteškoća sa savladavanjem nastavne cjeline može zatražiti pomoć predloženog studenta koji je određenu nastavnu aktivnost uspješno savladao i opravdao znanje kroz ranije navedenu 10-minutnu provjeru znanja. Landers i Callan (2011.) naglašavaju kako je na kraju istraživanja **113 od ukupno 385 studenata** osvojilo ukupno **546 certifikata**.

Landers i Callan također ističu kako interne (sveučilišne) **društvene mreže** mogu pozitivno utjecati na motiviranost studenata. **Nagrađivanje** studenata treba biti eksplicitno i u društvenoj mreži prepoznato jer što je jasnija nagrada i što je ona studentima vrjednija, to će i motiviranost biti veća. Nagrada bi trebala biti **usklađena s težinom** željene aktivnosti ili provjere znanja. **Težina** se treba postepeno graditi. **Povratne informacije** za aktivnosti i provjere znanja trebale bi biti trenutne. Potrebno je paziti na **vizualan izgled** i **ambijent** u kojemu se nastavni materijali izučavaju.

Muntean (2011.) povezuje stanje tijeka (eng. *flow*) koje se detaljno opisuje u poglavlju 3.4. ove doktorske disertacije s istraživanjem B.J. Fogga koji je 2009. godine predložio tzv. *Foggo Model Ponašanja* (eng. *Fogg's Behavior Model*), a koji se temelji na (a) **motivaciji**, (b) **sposobnostima** i (c) **pokretačima određenih aktivnosti**. Prema Muntean (2011.), **motivacija** može biti uzrokovana osjećajem ugone ili boli, strahom ili nadom, te društvenim statusom koji može biti prihvaćanje ili odbijanje. Ako kod studenta postoji visok stupanj motivacije, ali nedostaje određen stupanj **sposobnosti**, promjena u ponašanju i/ili učinkovit proces učenja neće biti ostvaren. Muntean nadalje navodi kako je uz navedeno potrebno uključiti i **pokretače određenih aktivnosti** (eng. *triggers*), odnosno elemente koji studentu sugerira da napravi određenu aktivnost u određenom trenutku. Pokretači mogu biti jednostavna signalizacija, pa sve do naratora koji u ključnom trenutku reagira i usmjerava studentovu aktivnost. Preduvjet za navedeno je stupanj obrazovanja studenta u kojem je student u mogućnosti **prepoznati, naučiti i zaključivati** na temelju prikazanih informacija. Stanje koje se javlja, prilikom aktiviranja svih tri elemenata, naziva se stanje tijeka.

Muntean (2011.) ističe kako postoji **problem u radu s e-tečajem** prilikom prenošenja poticaja ili emocije koja je prisutna u interakciji između nastavnika i studenta. Upravo iz navedenog razloga sustavi za e-učenje trebaju biti prošireni s tehnološkim rješenjima koja utječu na **motiviranost** i potiču studente na **uključenost u nastavne aktivnosti**.

U nastavku ovog dokorskog rada navode se elementi mehanike iz računalnih igara koji se mogu koristiti za poticanje intrinzične motivacije.

Tablica 20. Poveznica između mehanike računalnih igara i intrinzične motivacije (prilagođeno prema Muntean, 2011.)

		Intrinzična motivacija					
		Nagrađivanje	Status	Postignuće	Samo izražavanje	Natjecanje	Altruizam
Mehanika računalnih igara	Bodovi	✓	o	o		o	o
	Nivoi		✓	o		o	
	Izazovi	o	o	✓	o	o	o
	Virtualna valuta	o	o	o	✓	o	
	Top lista		o	o		✓	o
	Poklanjanje		o	o		o	✓

Muntean (2011.) navodi da je za ispravnu gemifikaciju e-učenja potrebno postepeno otkrivati nastavni sadržaj, te staviti naglasak na ponavljanje, vježbanje i provjeru znanja. Za ispravna rješenja, studentu je potrebno osigurati dodjelu bodova.

Cilj koji se želi postići gemificiranjem e-učenja je osigurati **višu motivaciju** kod studenata, kao i **uključenost** studenata u nastavne aktivnosti koje su dostupne u gemificiranom sustavu. Muntean navodi ako su **studenti** duže u sustavu, kako je vrlo vjerojatno da će ostvariti **bolji rezultat** na provjeri znanja. Slijedom navedenog studenti će nastavne aktivnosti u budućnosti brže savladati uz postizanje boljih rezultata. U tradicionalne sustave za e-učenje nastavnik, administrator ili dizajner e-tečaja treba uključiti neke od sljedećih elemenata računalnih igara: **avatar** (eng. *avatar*), **podsjetnik s novostima** (eng. *notification*), **odvojene nastavne cjeline** (eng. *chapters*) te **odvojene nastavne razine** (eng. *levels*). Zaključuje se kako student nakon savladavanja određenih nastavnih cjelina napreduje u više nastavne razine gdje se postupak savladavanja novih nastavnih cjelina ponavlja uz korekciju težine zadataka za ponavljanje i korekciju apstrakcije nastavnih materijala.

Prema Munteanu (2011.) e-tečaj bi studente trebao nagrađivati ne samo za njihova akademska postignuća, nego i za određen vid ponašanja, poput **pomaganja i komuniciranja** s ostalim sudionicima e-tečaja. Uz navedeno, važno je osigurati da studenti znaju što su im obaveze i što ih očekuje u sljedećoj nastavnoj cjelini. Također, važno je kreirati osjećaj **iznenađenja i iščekivanja** kako bi se utjecalo na motivaciju polaznika u trenutku otkrivanja novih elemenata *gemificiranog* sustava.

Barata i suradnici (2013.) provode istraživanje u trajanju od **dvije godine**. Elementi računalnih igara (bodovi, razine, top-lista, izazovi i bedževi) uključuju se u Moodle sustav s ciljem pozitivnog utjecaja na zainteresiranost studenata visokoškolskog obrazovanja. Istraživanje je bilo usmjereno na **motivaciju i ishode učenja**, ali zbog duljine trajanja javljaju se znatna odstupanja u provedbi eksperimenta: **nejednaki broj ispitanika** po grupama, **nejednaki nastavni materijali**, te **nejednaki uvjeti** u kojima se održavala nastava.

Rezultat istraživanja bio je **veći interes studenata** za predavanja i za sudjelovanje u e-tečaju, proaktivnost te veće korištenje nastavnih materijala. Barata i suradnici navode kako istraživanje ne pokazuje direktan utjecaj motivirajućih elementa računalnih igara na postignute ocjene iz kolegija te se navedeno predlaže za **buduće razmatranje** i dodatno istraživanje.

Jayasinghe i Dharmaratne (2013.) istražuju učenje pomoću edukativnih računalnih igara i učenje pomoću elemenata računalnih igara bez prisutnosti igre u području **programiranja**. Istraživanje je provedeno nad **60 studenata** koji ranije nisu imali edukaciju iz područja programiranja, točnije programskih algoritama sortiranja. Eksperiment je trajao **60 minuta**, te je sadržavao bodove i povratne informacije o točnim odgovorima koje su studenti dobivali. Studenti su podijeljeni u 4 grupe po 15 ispitanika. Dvije grupe su *eksperimentalne*, dvije su *kontrolne*. Statistička značajnost razlike u bodovima između grupa nije računata, već su grupe podijeljene prema ranije postignutim ocjenama iz matematike. Algoritmi sortiranja koji su korišteni u istraživanju bili su sortiranje **zamjenom susjednih elemenata** (eng. *Bubble sort*) i **segmentno sortiranje** (eng. *Bucket sort*).

Rezultati istraživanja Jayasinghe i Dharmaratne (2013.) govore kako su njihove obje *eksperimentalne* grupe imale više prosječne bodove. U slučaju sortiranja zamjenom susjednih elemenata prosječan rezultat obje *eksperimentalne* grupe bio je veći za 21,3% u odnosu na obje *kontrolne* grupe. U slučaju segmentnog sortiranja prosječan rezultat kod obje *eksperimentalne* grupe bio je veći za 25,3% u odnosu na obje *kontrolne* grupe. Uz prosječne bodove mjereno je i vrijeme u kojem su studenti učili nastavne materijale iz područja programiranja. Zaključak je kako su obje *eksperimentalne* grupe savladale nastavne materijale u gotovo **dvostruko manje vremena** od obje *kontrolne* grupe ispitanika čime se i završava istraživanje.

de-Marcos i suradnici (2014.) razvili su *gemificirani* dodatak za **BlackBoard LMS** sustav koji je omogućio **praćenje nastavnih aktivnosti** ukupno **371 studentu**, isto kao i međusobnu suradnju, ali i međusobno natjecanje. Nastavne aktivnosti vezane su za četiri područja i to za obradu teksta, proračunske tablice, izradu prezentacija te baze podataka. Svaka aktivnost predstavljena je kao izazov i podijeljena je na nekoliko razina kako bi studenti postigli osjećaj napredovanja. E-tečaj je bio otvoren za studente u trajanju od **jednog semestra**. Bio je aktivan 6-10 sati tjedno. Nakon svake razine studentu je dodijeljen bedž u obliku trofeja. Nekoliko bedževa bilo je skriveno kako bi studenti bili iznenađeni i dodatno motivirani.

U istraživanju de-Marcos i suradnika (2014.), suradnja i dijeljenje postignuća bilo je osigurano putem foruma. Uz *gemificirani* dodatak za praćenje nastavnih aktivnosti, razvijena je i web platforma koja je studentima osiguravala pristup video materijalima i blogovima. Studentima je bilo omogućeno praćenje drugih korisnika kroz tzv. slijedi funkciju (eng. *follow*). Studenti su imali mogućnost postavljanja kratkih poruka, označavanja slaganja s tuđim mišljenjem kroz funkciju sviđanja (eng. *like*), isto kao i komentiranja ostalih aktivnosti.

Istraživanje de-Marcos i suradnika koristi tri istraživačke grupe, gdje je prva grupa (od 114 ispitanika) izložena **gemificiranom e-tečaju**, druga grupa (od ukupno 184 ispitanika) kreirana od strane de-Marcos i suradnika, izložena je **društvenoj mreži**, a treća grupa (od 73 ispitanika) bila je kontrolna grupa koja je koristila **klasičan e-tečaj**. Eksperiment je proveden **tijekom 2012.** godine. Mjesto istraživanja bili su različiti sveučilišni centri ovisno o grupi polaznika. de-Marcos i suradnici koristili su *predtest* i *posttest* metode za provjeru studentovog znanja te *anketni upitnik* (od 10 pitanja) koji je prikazan samo prvoj i drugoj skupini ispitanika.

Predtest je korišten za provjeru znanja između svih triju grupa. Rezultati *predtesta* ukazuju kako između grupa nije postojala statistički značajna razlika. Temeljem *posttest* provjere znanja utvrđeno je kako su obje *eksperimentalne* grupe postigle bolje rezultate u **praktičnom dijelu** provjere znanja u odnosu na *kontrolnu* grupu u sve četiri nastavne cjeline (obrada teksta, proračunske tablice, izrada prezentacije i baze podataka). Grupa koja je koristila **društvene mreže** postigla je bolje rezultate u prve dvije nastavne cjeline (obrada teksta, proračunske tablice) u odnosu na grupu koja je koristila **gemificirani** dodatak unutar BlackBoard okruženja. Ostali rezultati se statistički nisu razlikovali.

Zanimljivo je kako su studenti *kontrolne* skupine postigli bolji rezultat od obje *eksperimentalne* grupe po pitanju pisane provjere znanja, gdje je grupa koja je koristila **društvene mreže** postigla bolji rezultat od grupe koja je koristila **gemificirani** dodatak. Unutar pisane provjere znanja sva tri rezultata osiguravaju statistički značajnu razliku. de-Marcos i suradnici (2014.) zaključuju kako obje *eksperimentalne* grupe stavljaju veći naglasak na **praktična vještine**, gdje su **teorijska znanja zanemarena**. Autori su uočili problem gdje su obje *eksperimentalne* grupe pokazivale vrlo **slab interes** za nastavnim materijalima. Otprilike 20% studenata aktivno je sudjelovao u navedenom istraživanju čime se stavlja naglasak i na dizajn istraživanja. Potrebno je ponoviti navedeno istraživanje kod kojeg bi se pažnja usmjerila na **društvenu komponentu** umjesto na postignuća, bedževe i međusobno natjecanje.

Iosup i Epema (2014.) kreirali su dva tečaja koja su provedena **četiri semestra** nad **450 studenata**. Iosup i Epema gemifikaciju smatraju kao set alata kojim se može utjecati na motivaciju i ponašanje korisnika. Istraživači navode sedam gemifikacijskih elemenata koji su podijeljeni u dvije kategorije: mehaniku i dinamiku. Mehanika definira kako igra funkcionira kao sustav, dok dinamika definira interakciju igre i korisnika. Unutar mehanike računalnih igara nalaze se bodovi, nivoi i ljestvica uspjeha. Unutar dinamike računalnih igara uključuju se bedževi, objašnjenje za početnika, društvene petlje i postepeno otključavanje sadržaja.

Uočeno je kako je preko 75% studenata položilo provjeru znanja na prvom ispitnom roku. Uočena je i pozitivna korelacija između studenata koji su položili provjeru znanja i zadovoljstva koje se pripisuje *gemificiranim* elementima. Uočeno je kako je gotovo 100% studenata pristupilo bonus nastavnim materijalima iako se nisu bodovali za ukupnu ocjenu. Studenti koji nisu uspješno položili provjeru znanja u 90% slučajeva ponovno pristupaju provjeri. Studenti koji su položili provjeru znanja u 5% slučajeva ponovno pristupaju provjeri s ciljem još boljeg rezultata.

Laskowski i Badurowicz (2014.) provode istraživanje u okviru prve godine diplomskog studija u trajanju od **jednog semestra**. Uzorak ispitanika broji **62 studenta** koji su raspoređeni u četiri grupe. Dvije grupe su *eksperimentalne*, dok su dvije *kontrolne*. *Eksperimentalne* grupe bile su u sustavu koji dodjeljuje **bodove** i **bedževe** polaznicima za postignuća, te omogućuje **ljestvicu poretka**. Prilikom analiziranja rezultata, na kraju semestra u obzir su uzeti sljedeći pokazatelji: broj dolaska na redovnu nastavu, broj riješenih zadataka, prosječna ocjena i slične informacije poput rješavanja domaćih zadataka i izrada projektnih zadataka koji se tijekom semestra prikupljaju. Cilj Laskowskog i Badurowicza bio je ispitati utjecaj korištenja elemenata računalnih igara, bez prisutnosti igre, na motiviranost studenata.

Rezultati istraživanja Laskowskog i Badurowicza (2014.) pokazuju kako *eksperimentalne* grupe ispitanika imaju višu stopu dolazaka na nastavu (97%) u odnosu na *kontrolne* grupe ispitanika (85%), isto kao i broj riješenih individualnih zadataka (1,7) u odnosu na *kontrolne* grupe ispitanika (1,37). Međutim, prosječna ocjena na kraju semestra je kod *eksperimentalne* grupe 3,83 od 5, dok je kod *kontrolne* grupe 4.53 od 5. Laskowski i Badurowicz potvrđuju kako se gemifikacija može koristiti za motiviranje studenata, no ne mogu pronaći poveznicu između više ocjene kod *kontrolne* grupe ispitanika i nižeg prisustvovanja nastavnim aktivnostima. Zaključuju istraživanje s napomenom kako se istraživanje treba ponoviti uz veći broj ispitanika, uz provedenu *pretest* i *posttest* provjeru znanja.

González i Carreño (2014.) istražuju koji elementi računalnih igara mogu biti korišteni u tradicionalnom obrazovanju, e-učenju i hibridnom učenju po pitanju uključenosti studenata u obrazovni proces. González i Carreño navode **Werbachov 6D** model, kao i pojedine elemente dinamike, mehanike i estetike koji se koriste i unutar ove disertacije. Uzorak koji se koristi u istraživanju Gonzáleza i Carreña (2014.) broji **100 studenta** treće godine preddiplomskog studija računalnog inženjerstva. Istraživačke aktivnosti provodile su se ukupno **četiri tjedna**. Metodologija istraživanja svodi se na metodu opservacije, metodu intervjua i *anketni upitnik*. Sva tri instrumenta preuzeta su od drugih istraživača.

Gonzáleza i Carreña za potrebe istraživanja izrađuju vlastitu platformu unutar koje su implementirani **bodovi, ljestvica poretka, grupe korisnika, avatar, virtualni objekti** i sl. Moodle platforma je odbačena jer nije zadovoljavala programsku arhitekturu poslužitelja koji je korišten u istraživanju. Detaljnijih objašnjenja za odbacivanje Moodle platforme nema.

González i Carreño (2014.) zaključuju kako gemifikacija ili elementi računalnih igara bez prisutnosti same igre mogu zadovoljiti osnovne ljudske želje ili potrebe poput: identiteta, nagrada, postignuća, natjecanja, suradnje, samo izražavanja i altruizma. Studenti su pokazali kako su im navedeni elementi važni u svakodnevnom životu, isto kao i u virtualnom okruženju u kojem im se predstavljaju nastavni materijali. Socijalna komponenta posebno je važna, pri čemu se razlikuje suradnja i međusobno natjecanje, kao i samostalan te timski rad. González i Carreño navode kako gemificirana rješenja potiču studente na veću razinu uključenosti bilo da se radi o formalnom ili neformalnom obrazovanju, zbog pojave koja se opisuje kao **stanje toka**. Stanje toka objašnjeno je u **poglavlju 3.4.** ove doktorske disertacije.

Stokes (2014.) upozorava na to da obrazovni sustav, kakav je sada prisutan, funkcionira na principu svojevrsnog "**oduzimanja bodova**" s obzirom na **broj grešaka**. Student ne smije pogriješiti, što dovodi do **stresa** i dodatnog **pritiska**, čime se negativno utječe i na njegovu motivaciju. Obrazovni sustav trebao bi prepoznati stupanj motivacije i navođenje studenata na ispravan put kroz elemente računalnih igara. Deterding (2015.) ističe kako **elementi računalnih igara** direktno **utječu na motivaciju i osjećaj uključenosti**, što uvelike koriste marketinške kompanije i djelatnici koji rade u području ljudskih resursa. Ortega de-Marcos i suradnici (2014.) potvrđuju pozitivan stav i bolju motivaciju kod ispitanika, uz postizanje **boljih ishoda** učenja za vrijeme prisutnosti elemenata **društvenih mreža** u obrazovnom sustavu. Hamari i suradnici (2014.) dolaze do zaključka koji potvrđuje istraživanja Deterdinga i dijelom istraživanja de-Marco i suradnika. Unutar akademskog obrazovanja istraživači Smole, Diniz i Milani (2007.) objavljuju da u radu s elementima računalnih igara studenti mogu učiti i razvijati svoje samopouzdanje na razne načine, kao što su interakcija i kolaboracija, kritička i problemsko orijentirana promišljanja, samoanaliza rada i aktivnosti te trenutna povratna informacija o uspjehu ili neuspjehu, gdje se neuspjehu pristupa kao temelju za nove smjernice i učenja.

Dicheva i suradnici (2015.) u okviru jednog **FP7 projekta** istražuju na koji se nastavni sadržaj može primijeniti gemifikacija, te koji su najčešće korišteni elementi računalnih igara u obrazovnom sustavu.

Analiza Dicheva i suradnika uključuje **34 empirijska** rada koji su pronađeni unutar nekih od vodećih znanstvenih baza (*ACM Digital Library, IEEE Xplore, ScienceDirect, SCOPUS, Springer Link, ERIC* i *Google Scholar*). Dicheva i suradnici navode kako su bodovi, bedževi, nivoi, top ljestvice, status napretka, virtualne valute i avatar **najkorišteniji mehanizmi** računalnih igara koji se koriste u obrazovnom sustavu, od kojih su bodovi, bedževi, nivoi i top ljestvice mnogo više zastupljeniji elementi od ostalih. **Dizajn gemificiranog** sustava temelji se na vizualnom statusu, socijalnoj uključenosti i društvenim medijima, isto kao i na slobodi izbora, pozitivnom pristupu neuspjelim pokušajima te konstantnim povratnim informacijama.

Obrazovni stil koji je najviše pokriven unutar navedena 34 empirijska rada odnosi se na miješane tečajeve (eng. *Blended Learning Courses*). Na drugom mjestu su tečajevi sa ili bez *online* podrške, na trećem su masovni otvoreni *online* tečajevi (eng. *Massive Open Online Courses, MOOC*), zatim slijede edukativne web stranice, te gemificirane platforme za podršku korisnicima. Uz navedeno, najčešće pokrivena edukativna područja su **računalna znanost i IT, programiranje računalnih igara** te **STEM** područja.

Dicheva i suradnici (2015.) navode kako još uvijek nedostaju jasni pokazatelji koji objašnjavaju **utjecaj** elemenata računalnih igara **na motivaciju**. Nedostaju izvještaji o **osjetljivosti elemenata** računalnih igara i implementaciji **praktičnih obrazovnih gemificiranih rješenja**. Nedostaju izvještaji o **potrebi nastavnika** za učinkovito provođenje, praćenje i evaluaciju studenata unutar gemifikacijskog pristupa. Dicheva i suradnici naglašavaju i **negativno iskustvo** u kojem studenti nisu bili spremni na autonomnost, te se nije dovoljno ozbiljno pristupilo projektnom pristupu isto kao niti pristupu provjeri znanja, čime se rad i zaključuje.

Schreuders i Butterfield (2016.) istražuju mogućnosti za povećanje studentske uključenosti u nastavni proces i povećanje motivacije, te poboljšanje iskustva koje studenti imaju prilikom prolaska kroz obrazovni proces. Istraživanje je provedeno unutar sveučilišnog kolegija **računalne sigurnosti**. Istraživanje je trajalo **dvije godine** te uključuje **32 studenta**. Za potrebe istraživanja, Schreuders i Butterfield su kreirali posebno programsko rješenje otvorenog koda koje je osiguravalo transparentnost bodova, dodjelu različitih bodova za studentske aktivnosti kao i davanje povratnih informacija o uspješnosti studentskih aktivnosti.

Rezultati istraživanja ukazuju na pozitivne pokazatelje po pitanju kvalitativnih i kvantitativnih rezultata u provjerama znanja. Zabilježen je porast u zadovoljstvu koje su studenti imali prilikom prolaska kroz obrazovni proces, no rezultati nisu bili statistički značajni.

Schreuders i Butterfield (2016.) zaključuju kako je njihovo istraživanje, bez obzira na mali broj ispitanika, u skladu s ostalim istraživanjima koja govore o pozitivnim utjecajima gemifikacije na povećanje motivacije, te poboljšanje iskustva koje studenti imaju prilikom korištenja sustava za e-učenje. Dodatna istraživanja su nužna kako bi sustav visokoškolskog obrazovanja u većoj mjeri prihvatio elemente računalnih igara na svim razinama.

Neki od istraživača koji su provodili eksperimente nad studentima u okviru visokoškolskih institucija navedeni su u tablici 21. ove doktorske disertacije.

Tablica 21. Sažeti prikaz istraživačkih radova iz poglavlja 3.6. ove disertacije

Autor i godina istraživanja	Trajanje istraživanja	Broj ispitanika	Elementi računalnih igara
Landers i Callan (2011.)	1 semestar	385	Avatar, društvene mreže, bedževi, certifikati, forum
Jayasinghe i Dharmaratne (2013.)	60 minuta	60	Bodovi, povratne informacije
Barata i suradnici (2013.)	4 semestra	nepoznat	Bodovi, razine, top-lista, izazovi i bedževi
de Marcos i suradnici (2014.)	1 semestar	371	Bedževi, društvene mreže, forum, praćenje (eng. <i>follow</i>) i slaganje (eng. <i>like</i>) s drugim studentima, chat
Iosup i Epema (2014.)	4 semestra	450	Bodovi, nivoi, ljestvica uspjeha, bedževi, objašnjenje za početnika, društvene petlje i postepeno otključavanje sadržaja
Laskowski i Badurowicz (2014.)	1 semestar	62	Bodovi, bedževi, ljestvica poretka
González i Carreño (2014.)	nepoznato	100	Bodovi, ljestvica poretka, grupe korisnika, avatar, virtualni objekti
Schreuders i Butterfield (2016.)	4 semestra	32	Bodovi, povratne informacije,

Tablica 21. prikazuje neke od istraživača koji su za predmet istraživanja imali utjecaj gemifikacije na studente u visokoškolskom obrazovnom sustavu. Prikazuje se vremensko trajanje istraživanja isto kao i broj ispitanika. Navodi se i odabir elemenata računalnih igara temeljem kojih je kreiran gemificiran sustav svakog od istraživača.

Zaključci koji se iz navedenih istraživanja mogu sažeti jesu kako je potrebno paziti na vizualan izgled i ambijent u kojemu se nastavni materijali prezentiraju i izučavaju, te kako bi *gemificirani* sustavi mogli uključivati avatare, podsjetnik s novostima, odvojene nastavne cjeline, kao i odvojene nastavne razine. Navedeni mehanizmi uzet će se u obzir prilikom odabira elemenata računalnih igara koji će se uključiti u *gemificirani* sustav **predistraživanja** kao i u **prvo i drugo glavnog istraživanje**.

Problem koji je uočen kod istraživanja **de-Marcos i suradnika** (2014.), u kojemu su *eksperimentalne* grupe ispitanika pokazivale **vrlo slab interes** za nastavnim materijalima i gdje je otprilike 20% studenata aktivno sudjelovao u navedenom istraživanju, posebno će se nadgledati u okviru ovog doktorskog istraživanja kako se isto ne bi ponovilo. Također, sedam elemenata računalnih igara (bodovi, nivoi, ljestvica uspjeha, bedževi, objašnjenje za početnika, društvene petlje i postepeno otključavanje sadržaja) koje Iosup i Epema (2014.) navode, bit će razmatrano za uključivanje u *gemificirani* sustav, zajedno s ostalim elementima koji će biti objašnjeni u **poglavlju 4.3.**, s ciljem potvrđivanja rezultata koje Iosup i Epema navode.

Poseban naglasak staviti će se i na situaciju koja je vidljiva kod **Laskowski i Badurowicz** (2014.) kod kojih su *kontrolne* grupe ispitanika na kraju semestra postigle veće prosječne ocjene od *eksperimentalnih* grupa ispitanika, pri čemu su *kontrolne* grupe ispitanika imale niže prisustvovanje nastavnim aktivnostima. Laskowski i Badurowicz nisu mogli objasniti takav rezultat i naglašavaju kako se istraživanje treba ponoviti uz veći broj ispitanika, što će biti napravljeno u ovom doktorskome radu sa znatno većim brojem ispitanika (**ukupno 309**) i većim brojem uključenih elemenata računalnih igara (**ukupno 24**).

3.7. UTJECAJ KORIŠTENJA GEMIFIKACIJE NA NASTAVNIKE

Parreno i suradnici (2016.) istražuju utjecaj korištenja elemenata računalnih igara, bez prisutnosti igre, na nastavnike te navode sljedeći niz pitanja koja se analiziraju kroz njihovo istraživanje:

1. *Pokazuju li nastavnici u visokoškolskom obrazovanju **pozitivan stav** prema gemifikaciji?*
2. ***Koriste li** nastavnici u visokoškolskom obrazovanju gemifikaciju u svojim kolegijima?*
3. *Utječe li **spol** na **stavove** nastavnika o primjeni gemifikacije u visokoškolskom obrazovanju?*
4. *Utječe li **spol** nastavnika na **samu primjenu** gemifikacije u visokoškolskom obrazovanju?*
5. *Utječe li **dob** na **stavove** nastavnika o primjeni gemifikacije u visokoškolskom obrazovanju?*
6. *Utječe li **dob** nastavnika na **samu primjenu** gemifikacije u visokoškolskom obrazovanju?*
7. *Utječe li **tip obrazovne institucije** na **stavove** nastavnika o primjeni gemifikacije u visokoškolskom obrazovanju?*
8. *Utječe li **tip obrazovne institucije** na **samu primjenu** gemifikacije u visokoškolskom obrazovanju?*

Istraživanje je provedeno putem *online* ankete koju su inicijalno poslali **Parreno i suradnici**, te se u nastavku poticalo nastavnike na daljnja prosljeđivanja ankete svojim kolegama putem web poveznice. Ukupno **98 nastavnika** je pristupilo istraživanju, prosječne dobi od 44 godina. Muškom spolu pripadalo je 56.25% nastavnika.

Tablica 22. Utjecaj i primjena gemifikacije u visokoškolskom obrazovanju
(prema Parreno i suradnici, 2016.)

<i>1. Pokazuju li nastavnici u visokoškolskom obrazovanju pozitivan stav prema gemifikaciji?</i>		
	Prosječna vrijednost	Standardna devijacija
Da, sviđa im se ideja	4.42 od maksimalno 5 bodova	0.807
Da, imaju pozitivan stav	4.35 od maksimalno 5 bodova	0.808

<i>2. Koriste li nastavnici u visokoškolskom obrazovanju gemifikaciju u svojim kolegijima?</i>		
	Učestalost	Postotak
Ne, nikada	61	38.10
Ponekad	81	50.60
Da, stalno	18	11.30

Iz tablice 22. vidljivo je kako su nastavnici u istraživanju imali pozitivan stav o korištenju gemifikacije u nastavi, ali samo 18 od ukupno 98 nastavnika (11.30%) gemifikaciju primjenjuje u praksi. Navedeno je i očekivano s obzirom na to da je pojam poprilično nov i nedovoljno dokumentiran u stručnoj i znanstvenoj literaturi.

Na treće pitanje: "*Utječe li spol na stavove nastavnika o primjeni gemifikacije u visokoškolskom obrazovanju?*", isto kao i na četvrto pitanje: "*Utječe li spol nastavnika na samu primjenu gemifikacije u visokoškolskom obrazovanju?*" odgovor je također bio **negativan**. Spol ne utječe na stavove o gemifikaciji isto kao niti na samu primjenu. Odgovori su temeljeni na analizi i izračunu t-testa u kojemu između navedenih ispitanika nije postojala statistički značajna razlika.

Na peto pitanje: "*Utječe li dob na stavove nastavnika o primjeni gemifikacije u visokoškolskom obrazovanju?*", isto kao i na šesto pitanje: "*Utječe li dob nastavnika na samu primjenu gemifikacije u visokoškolskom obrazovanju?*" odgovor je bio **negativan**. Dob nije povezana sa stavovima niti primjenom gemifikacije. U analizi, Parreno i suradnici (2016.) nisu pronašli značajnu pozitivnu korelaciju po pitanju dobi ispitanika.

Na sedmo pitanje: "*Utječe li tip obrazovne institucije na stavove nastavnika o primjeni gemifikacije u visokoškolskom obrazovanju?*" odgovor je bio **pozitivan**. Pokazano je kako nastavnici privatnih visokoškolskih institucija imaju pozitivniji stav prema primjeni gemifikacije, za razliku od nastavnika javnih visokoškolskih institucija. U slučaju osmog pitanja: "*Utječe li tip obrazovne institucije na samu primjenu gemifikacije u visokoškolskom obrazovanju?*" odgovor je bio **negativan**. Rezultati ukazuju na nepostojanje statistički značajne razlike u odgovorima između privatnih i javnih obrazovnih institucija.

Parreno i suradnici (2016.) naglašavaju kako postoji pozitivan utjecaj korištenja elemenata računalnih igara na nastavnike visokoškolskih institucija, ali izostaje primjena navedenog pristupa u praksi. Samo 11.30% ispitanika koristili su metode gemifikacije ili edukacijske računalne igre u svom radnom okruženju. Zaključuje se kako dob, spol i vrsta obrazovne institucije statistički značajno ne utječe na stavove nastavnika. Glavni problemi s kojima se nastavnici susreću vezani su uz informacijsko-komunikacijsku tehnologiju i IT rješenja koja postoje u pojedinom radnom okruženju, isto kao i mogućnost pravilne i pravovremene edukacije nastavnika. Spomenuto se nadovezuje na nedostatak vremena za edukaciju i na nedostatak financijskih sredstava. Parreno i suradnici predlažu dodatna istraživanja navedenog područja.

U tablici 23. prikazani su odnosi između najčešćih mehanizama računalnih igara i igrača (korisnika sustava) koji služi nastavnicima, dizajnerima i/ili administratorima *gemificiranih* obrazovnih sustava kao **preporuka** u fazi planiranja.

Tablica 23. Tipovi korisnika i elementi računalnih igara pogodni za korištenje u e-učenju (kreirao autor disertacije prema **Taspinar i suradnici**, 2016.)

Tipovi korisnika / Igrača				Mehanizam	Opis
P*	S*	D*	I*		
✓	✓			Jasni ciljevi	Jasno objašnjeni elementi koji se žele postići
✓	✓	✓	✓	Epsko značenje	Dodjeljivanje smisla nastavnim aktivnostima
✓	✓		✓	Izazovi, zadaci, misije	Elementi koji iziskuju problemsko djelovanje
✓	✓		✓	Odbrojavanje	Vremensko ograničenje za određenu aktivnost
✓	✓			Transparentnost	Korisnik je upoznat s mogućim ishodima svojih aktivnosti u sustavu
✓	✓			Povratna informacija	Trenutna povratna informacija o aktivnostima
✓	✓	✓	✓	Uvjetovane informacije	Informacije se postepeno otkrivaju kako korisnik prolazi kroz (koristi) sustav
✓	✓		✓	Sakupljanje bodova	Numerička vrijednost dodijeljena aktivnostima
✓	✓		✓	Bedževi za postignuća	Virtualan simbol koji se dodjeljuje po završetku određene aktivnosti
✓	✓	✓	✓	Poticajna nagrada	Nagrađivanje za postignuće drugih sudionika
✓	✓			Gubitak bodova, statusa	Oduzimanje bodova, statusa, postignuća
✓	✓			Top ljestvica	Instrument za usporedbu između sudionika
✓	✓			Napredovanje, nivo	Prikazuje uspjeh i daje uvid u sljedeću razinu
	✓	✓	✓	Kolaboracija	Rješavanje zadataka u grupnom radu

*P = Pobjednik, S = Sakupljač, D = Društvenjak, I = Istraživač

Nastavnici, dizajneri i/ili administratori *gemificiranih* obrazovnih sustava trebali bi poznavati profil korisnika koji će koristiti njihovo obrazovno okruženje. Navedeno je moguće napraviti kroz *anketni upitnik* ili kroz analizu ranijeg rada korisnika u okviru obrazovnog sustava.

U okviru ove disertacije, u **poglavlju 3.3.** spominju se tipovi igrača gdje je najviše korištena podjela koju navodi **Richard Bartle** (1985.; 1996.). Ako se korisnicima pristupa kroz Bartleovu matricu, onda postoje četiri grupe igrača kojima korisnici sustava mogu pripadati, a to su *Pobjednik*, *Sakupljač*, *Društvenjak* i *Istraživač*. Potrebno je znati kako nije svaki od navedenih igrača zainteresiran za svaku aktivnost koja se u sustavu nalazi, te sukladno tome, treba voditi računa oko mehanizama računalnih igara koji se ugrađuju u obrazovni sustav.

Muntean (2011.) predlaže kako bi **nastavnici trebali osigurati** korištenje **bedževa** (eng. *badge*) i **bodova** (eng. *points*), te omogućiti ostvarivanje određenih **postignuća** (eng. *achievement*) i **prikazivanje statusa** (eng. *status*). Savjetuje se korištenje **ljestvice poretka** (eng. *leaderboard*), ali i **top liste najbolje rangiranih** studenata (eng. *top score*). **Povratna informacija** studentima mora biti dostupna cijelo vrijeme. Također, korisno je u e-tečaj uključiti povremene **virtualne sastanke** kako bi se studenti vratili u sustav neovisno o nastavnim materijalima. Muntean nadalje navodi kako bi *gemificirani* sustav trebao biti **društveno orijentiran** što je više moguće. Društvenost je važna za tip igrača koji traže priznanje ostalih polaznika e-tečaja. U e-tečaj dobro je uključiti i **dodatne** nastavne i nenastavne **elemente** (eng. *bonus*) koji se studentima stavljaju na raspolaganje u posebnim okolnostima.

Iosup i **Epema** (2014.) opisuju kako bi **prosječan nastavnik**, koji koristi elemente računalnih igara u obrazovnom procesu, trebao imati **napredno poznavanje računalnih alata** za upravljanje elementima računalnih igara, pogotovo ako se radi s velikim skupinama studenata. Potrebno je uložiti mnogo energije u **objašnjavanje novog sustava** studentima, isto kao i dobivanje odobrenja od organizacije koja je navikla raditi na drugačiji način. Dodatna prepreka može biti i **nedostatak tehničke podrške** visokoškolske institucije koja se ne nudi sve dok navedeni pristup ne pokaže pozitivne rezultate u određenoj situaciji i ne bude prihvaćen od većeg broja nastavnika.

Prema Iosupu i Epemi nastavnici, dizajneri i/ili administratori *gemificiranih* obrazovnih sustava trebali bi prilikom kreiranja *gemificiranog* e-tečaja osigurati minimalno **jedan tjedan** za razmatranje elemenata računalnih igara koji se uključuju u e-tečaj, te **jedan dan** za kreiranje nastavnih sadržaja jedne nastavne jedinice. Potrebno je izdvojiti **dva sata** za analizu pitanja za jednu nastavnu jedinicu, **dva dana** za unošenje rezultata svake provjere znanja, te **jedan tjedan** za analizu prolaznosti.

Obrazovni sustavi potpomognuti elementima računalnih igara doživjet će veću upotrebu u godinama koje dolaze uslijed sve većeg broja istraživača i korisnika gemifikacije diljem svijeta.

3.8. PEDAGOŠKI I PSIHOLOŠKI ASPEKT UVOĐENJA GEMIFIKACIJE U OBRAZOVNI SUSTAV

Versteeg (2013.) navodi da igranje igara korisnicima omogućuje smanjenje osjećaja za **vrijeme** i **prostor** u kojem se nalaze. Deterding i suradnici (2011.), Rajić (2011.), Stokes (2014.), Versteeg (2013.) i drugi govore kako se **gemifikacija temelji na pozitivnoj psihologiji** koja dovodi do veće motiviranosti korisnika. Deterding (2012.) i McGonigal (2011.) naglašavaju da, s pedagoškog i psihološkog aspekta uvođenja elemenata računalnih igara u obrazovni sustav, znanstveni radovi upućuju na **pozitivan ishod učenja** i razvijanje vještina kritičkog i problemski orijentiranog razmišljanja. Dodaju da isto vrijedi i za **osjećaj povezanosti i dublje razumijevanje** teme koja se proučava. Istraživači Adeel (2014.), Smole, Diniz i Milani (2007.), Fitz-Walter (2015.) i drugi tvrde da se *gemificiranim* pristupom utječe na ponašanje za vrijeme učenja, potiče komunikacija, interakcija, kolaboracija i trenutna povratna informacija o statusu uspjeha studenta, gdje se neuspjehu pristupa s ohrabrenjem i novim smjernicama za učenje. Fitz-Walter (2015.) upozorava na to da postoje istraživanja u kojima je **gemifikacija uklonjena** iz sustava jednom kada su je korisnici imali prilike koristiti te je kao rezultat nastala značajna odsutnost korisnika. Fitz-Walter zaključuje da gemifikacija ima određeni utjecaj i **može utjecati na ponašanje** korisnika.

Ragupathi (2012.) naglašava da je za uspješno kreiranje gemificirane platforme potrebno **poznavati profil polaznika** te osmisliti grafički izgled i pozadinsku priču koja nastavni sadržaj čini zanimljivijim. Potrebno je definirati **jasne ciljeve**, način **pristupa** nastavnim sadržajima i način **ocjenjivanja** studenata, nakon čega se može očekivati **efikasniji rad, viša razina motivacije i bolji rezultati** u provjerama znanja.

Deterding i suradnici (2011.), McGonigal (2011.), Werbach i suradnici (2012.), Ragupathi (2012.), Fitz-Walter (2015.) i drugi navode **mehanizme računalnih igara** koji doprinose **psihološkim i pedagoškim** promjenama kod studenata: trenutni sustav nagrađivanja, osjećaj napredovanja, mali pomaci u vidu ciljeva, usputni kratki zadaci, otključavanje skrivenih elemenata i dodjeljivanje postignuća, javno vidljiva lista najboljih studenata i njihovog stupnja izvrsnosti, integracija društvenih mreža i sl. Elementi koji predstavljaju moguće probleme u gemificiranom sustavu su **balansiranje** težine i nagrada, **vrijeme izrade** gemificirane platforme, **zanimljivost sadržaja** i popratna **priča**. Također, nastavniku može se smanjiti potrebno vrijeme za ocjenjivanje, dobivanje i davanje povratnih informacija. Zaključuje se kako gemifikacija, uz dodatni angažman nastavnika, **može poboljšati interakciju** između studenata i nastavnika te osigurati **efikasnije usmjeravanje** studentskog **rada i aktivnosti**.

Bíró (2014.) govori o gemifikacijskoj teoriji kojom se pristupa pedagoškim problemima efikasnije od ranijih obrazovnih teorija (bihevioristička, kognitivna, konstruktivna, konektivna). Gemifikacijska teorija posjeduje teoretski okvir koji osigurava cjelokupan proces obrazovanja i potrebne popratne elemente, iz čega se zaključuje da bi se gemifikacija trebala definirati kao moguća nova teorija učenja uz daljnja istraživanja primjene i njenih mogućnosti u visokoškolskom obrazovanju, gdje se autor ove disertacije uključuje s nadom potvrđivanja i proširivanja navedenih tvrdnji.

3.9. OSNOVNI PRINCIPI UČENJA POMOĆU ELEMENATA RAČUNALNIH IGARA

Lovett i suradnici (2016.) iz centra "*Carnegie Mellon's Eberly*" za obrazovnu izvrsnost navode četiri principa koji opisuju kako u tradicionalnim uvjetima učimo u usporedbi s učenjem koje je temeljeno na elementima računalnih igara.

Princip 1: Ispitanici su često izloženi raznim okolnostima i situacijama u kojima stječu znanje poučavano tradicionalnim metodama. Ta ranija znanja mogu biti korisna ako je tematika o kojoj se govori korektno naučena te će u takvom slučaju nastavak učenja biti lakši i brži. Suprotna situacija je u slučaju kada je predznanje studenta temeljeno na krivim činjenicama ili navikama. Za pravilno učenje u takvoj situaciji treba proći više vremena kako bi se upozorilo i ispravilo krivo tumačenje novog znanja. Zbog iznimne **dinamike i vizualnih pomagala** koja su dostupna u sustavima baziranim na elementima računalnih igara ili se čak i primjenjuju računalne igre u cijelosti, loše navike ili netočne informacije brže se ispravljaju zbog **trenutne povratne informacije** u vidu sudara, eksplozije ili druge vizualizacije pokazatelja pogreške.

Princip 2: "*Generacija Z*", koja se spominje u poglavlju 2.1.7., slabije tolerira tradicionalan pristup obrazovanju te preferira **dinamične i interaktivne** sustave kroz koje mogu razviti vještine i nova znanja (Ramar, 2016. i Owens, 2016.). Ovakvi sustavi temelje se na povratnim informacijama o uspjehu u vidu bodova i evaluacije. Čest je slučaj da studenti ponovno prolaze kroz sustav **nakon prethodno uspješno prijeđenog poglavlja** radi dobivanja maksimalnog broja bodova i rezultata, čime se aktivno razvija konzistentno i produktivno praktično znanje.

Princip 3: Učenje bazirano na elementima računalnih igara ili primjenom računalnih igara u cijelosti osigurava **dinamičnu brzinu** prolaska kroz sustav, čime je zadovoljen **zabavni i motivacijski faktor** zadržavanja pažnje studentima koji brže uče, kao i studentima kojima treba znatno **više vremena** za svladavanje iste količine nastavnih sadržaja.

Tradicionalan sustav u ovom aspektu ima problema koji se mogu riješiti dodatnim naporom nastavnika u vidu pripremanja **dodatnih** nastavnih materijala **za nadarene** pojedince i **dopunskih** nastavnih materijala za pojedince koji su **ispodprosječnih** sposobnosti. Sustav temeljen na računalnoj igri, koji je pravilno dizajniran, može osigurati aktivno učenje za navedene tipove studenata, gdje se nastavna cjelina implementira u realistično okruženje s naglaskom na vizualne povratne informacije o pravovremenim odlukama i trenutnim posljedicama.

Princip 4: Sustav u kojemu studenti uče treba biti konzistentan, transparentan i jasan u mnogim pitanjima - od samih ciljeva učenja, povratnih informacija o uspješnosti studentskih aktivnosti, napredovanja, testiranja znanja, pa sve do navigacije između nastavnih cjelina. Tradicionalni pristup **ne može osigurati konzistentne, individualne** i pravovremene **povratne informacije** zbog svoje tromosti. Vježbe su često ograničene brojem ponavljanja i samim trajanjem, što nije slučaj u e-tečaju. Sustavi koji se razmatraju trebali bi uključivati zabavne elemente s uporištem u praktičnim problemskim situacijama, koji bi **reagirali** na svaku **studentovu akciju** u vidu bodova, pohvala, pokazatelja uspjeha prilikom završene razine ili, u suprotnom, posljedicama koje alarmiraju na pogrešku u odlučivanju. **Rezultat je motivacija** za usavršavanje i rješavanje konkretnog problema, što ima direktan utjecaj na razinu i kvalitetu naučenog praktičnog znanja.

U knjizi "*Gamification 101: The Psychology of Motivation*" autor (Michael, 2012.) pokazuje usporedbu najčešćih pristupa obrazovanju s obzirom na nastavu baziranu na računalnim igrama (*eng. Game Based Learning, GBL*). Michael navodi kako je **unutarnja motivacija** ostvarena **osjećajem svrhe i dodanim interesom** za temom. Navedeno se postiže **pričom, autonomijom** studenata i osjećajem **svladavanja novih vještina**. Vanjska motivacija povezana je sa sustavom nagrađivanja, tj. bodovima, certifikatima, natjecanjem i izazovima. Michael (2012.) ističe kako se ukupna promjena na razini sustava odnosi na podizanje motivacije i pozitivan utjecaj na emociju, koncentraciju, znatiželju, primjenu, pamćenje i stvaranje studenta, bilo da se radi o klasičnom osvrtu ili kreativnom rješenju problema.

3.10. GEMIFIKACIJA KAO "PETA TEORIJA UČENJA"

Bíró (2014.) navodi da se gemifikacija do sada nije sagledavala kao moguća teorija učenja, niti kao kompleksni pedagoški fenomen koji sadrži inovativne teorijske pristupe motiviranja korisnika obrazovnog procesa. Inovativni pristupi prilikom prenošenja znanja su od posebne važnosti kada se govori o novim generacijama učenika i studenata koje se često nazivaju "*Generacijom Z*" (generacijska populacija rođena u prvih deset godina 21. stoljeća) a koju pobliže opisuju **Ramar** i suradnici (2016.) i **Owens** (2016.).

Osnovno **polazište motivacije** je **vlastita znatiželja** za otkrivanje novih, skrivenih, do tada nepoznatih elemenata sustava, kao i otkrivanje novih vještina koje se poučavaju. Znanje se nadograđuje na postojeća predznanja, ali se i analiziraju dosad naučene vještine radi ispravljanja mogućih pogrešaka. Učenje je proces kroz koji **student samostalno prolazi** u trenutku kada mu **najbolje odgovara**. Isto se odnosi i na brzinu kojom prolazi kroz nastavne cjeline. Bíró (2014.) ističe kako gemifikacijska teorija učenja, obrazovanje tretira kao sistematično-samostalan proces u kojemu se potiče **rad u skupinama** i **razmjena informacija** između sudionika u trenutku kada su za to spremni. Nastavnik upravlja obrazovnim sustavom te ga **usmjerava** i **osigurava** ispravno funkcioniranje nastavnih cjelina. **Polaznik** ima **autonomiju** u odabiru nastavne cjeline, vremena pristupa, brzini prolaska kroz sadržaj i sl. Ponašanje **nastavnika** i **polaznika** je **proaktivno**, gdje je cilj dostići maksimalan učinak učenja uz prisutnost **zabavnih aktivnosti** koje svoje uporište imaju u praktičnim primjerima.

Gemifikacijska teorija učenja ima potencijal da pedagoškim problemima pristupa efikasnije od ranijih obrazovnih. Bez obzira na to što se gemifikacija može analizirati i proučavati s aspekta suvremenog marketinškog alata, inovacijskog sustava za društveno-komunikacijske aktivnosti ili s aspekta metode za postizanjem višeg stupnja uključenosti u obrazovni proces, Bíró sugerira kako bi se **gemifikacija** obrazovnih sustava trebala detaljnije istražiti te uključiti kao nova teorija učenja, uz **bihevioristički**, **kognitivni**, **konstruktivni** i **konektivistički** pristup. Bíró zaključuje svoja razmatranja pozivom ostalim istraživačima za dodatnim empirijskim istraživanjima u visokoškolskom obrazovanju, gdje se autor ove disertacije uključuje radi potvrđivanja i proširivanja navedenih tvrdnji.

Bihevioristički pristup učenju i gemifikacija imaju zajedničke elemente (pozitivan utjecaj na motiviranje korisnika, trenutna povratna informacija, postupna težina zadataka i sl.), no Bíró (2014.) ističe kako se gemifikacija ne bi trebala promatrati kao nadogradnja postojeće teorije jer se temelji na društvenom sustavu procjenjivanja i evaluacije koji je još jedino vidljiv kod konektivističke teorije. Gemifikacijski pristup obrazovanju **potiče** korištenje kratkih aktivnosti koje se mogu rješavati prema slobodnoj volji polaznika, neovisno o njihovom redoslijedu. Navedeno je važno jer su grupe polaznika **samostalne** ali i **međusobno različite** te im je potrebno omogućiti vlastiti odabir pristupa aktivnosti u obrazovnom sustavu. **Vizualan izgled i grafičko sučelje** obrazovnog sustava posebno je važno za prikaz nastavnih i nenastavnih materijala, obrazovnog puta koji je student odabrao isto kao za prikaz **postignuća i napredovanja**, kao povratne informacije o uspješnosti studentovih aktivnosti.

Konstruktivistička teorija učenja navodi da je obrazovni proces jedinstven s obzirom na polaznika i određenu situaciju jer se znanje konstruira kroz sam proces učenja. **Gemifikacija** kao peta teorija učenja studentu **osigurava individualan odabir** obrazovnog puta prema kojemu se definiraju i obrazovne aktivnosti u određenom vremenu. Obrazovni sustav temelji se na **aktivnostima, evaluaciji postignuća i povratnim informacijama** uz korištenje društvenih komunikacijskih servisa (forum, chat, mail i dr.). Potrebno je osigurati pristup koji obuhvaća **raznolikost navika i očekivanja** polaznika sustava. Eksplicitno **definirana putanja** za stjecanje znanja ne postoji. Različiti obrazovni putovi podrazumijevaju različite metode prikupljanja informacija, što rezultira i različitim načinima kreiranja znanja. Bíró (2014.) naglašava kako gemifikaciju **ne treba miješati s programiranim učenjem** (eng. *programmed learning*) ili **učenjem kroz računalnu igru**, bez obzira na njihove dodirne točke.

Bíró (2014.) ističe kako **gemifikacijska i konektivistička teorija** učenja u svojim razmatranjima koriste **društvene mreže** te ih smatraju **vrlo važnima** društvenim servisima, iako im pristupaju s različitih stajališta. Konektivistička teorija definira društvene mreže kao komponentu koja se razvija zajedno s **obrazovnim procesom** i definira učenje kao **niz čvorova** koji se kroz **komunikaciju i interakciju** povezuju u cjelinu. Gemifikacijska teorija učenja pristupa društvenim mrežama kao temelju na kojem je razvijena strategija **društvene motivacije i povratnih informacija** zbog podizanja razine uključenosti u obrazovni proces i podizanje motivacije za učenjem kod studenata. Moglo bi se zaključiti da je za konektivistički pristup **društvena mreža** glavni element **obrazovnog sustava**, dok je za gemifikacijsku teoriju učenja **potporni element** kojim se **podiže motivacija polaznika**.

3.11. PRIMJERI ELEMENATA RAČUNALNIH IGARA U OBRAZOVNIM SUSTAVIMA

Prema navodima Chou (2014.) i Zichermann (2016.), u nastavku ovog rada navode se primjeri javno dostupnih *gemificiranih* obrazovnih rješenja.

Duolingo - kombinacija masivne *online* kolaboracijske platforme za besplatno učenje stranog jezika u kombinaciji s plaćenim (*crowdsourced*) prevoditeljskim sustavom teksta. Sustav je zamišljen kao potpora studentima u učenju stranog jezika, prilikom čega se pomaže u prijevodima web stranica i specifičnih dokumenata. Težina riječi i težina traženog prijevoda dinamički se povećava kako se povećava točnost rješenja, pri čemu studenti mogu dati svoj glas tj. ocijeniti kvalitetu drugog studenta osiguravajući povratnu informaciju o točnosti prijevoda. Najbolje ocijenjeni prevoditelji izloženi su javnosti, kao i njihovi prijevodi. Svakim odrađenim zadatkom skupljaju se **bodovi** i **vremenski bonusi** koji se mogu kasnije iskoristiti u novim zadacima. Uključenost studenata osigurava se sadržajem s Weba jer je zanimljiviji od prevođenja nasumičnih rečenica. Sustav *Duolingo* prikazan je na slici 23.

The screenshot displays the Duolingo interface for learning German. On the left, there are sections for 'German skills' (Basics 1, Basics 2, Phrases, Food, Animals) and 'Bonus Skill'. The middle section shows 'German progress' with a bar chart and a 'Strengthen skills' button. Below that is a 'Leaderboard' for 'All time' with users like Sanda-Panda (680 XP) and Andro-Panda (570 XP). On the right, there is a list of words with their parts of speech and spaced repetition progress bars. A 'Lingot store' is visible below the word list, offering power-ups like 'Heart Refill', 'Streak Freeze', and 'Double or Nothing'. The bottom right section shows 'PRACTICE' options like 'Timed Practice'.

Word	Part of Speech	Time	Progress
schuhe	Noun	1 week ago	Progress bar
kalt	Adjective	1 week ago	Progress bar
lesen	Verb	1 week ago	Progress bar
wahrscheinlich	Adjective	1 week ago	Progress bar
stark	Adjective	1 week ago	Progress bar
seid	Verb	1 week ago	Progress bar
toll	Adjective	1 week ago	Progress bar
früh	Adjective	1 week ago	Progress bar
gemeinsam	Adjective	1 week ago	Progress bar
klar	Adjective	1 week ago	Progress bar
ja	Adverb	1 week ago	Progress bar
schnell	Adjective	1 week ago	Progress bar
positiv	Adjective	1 week ago	Progress bar
richtig	Adjective	1 week ago	Progress bar
einfach	Adjective	1 week ago	Progress bar
möglich	Adjective	1 week ago	Progress bar
speisekarte	Noun	1 week ago	Progress bar
vegetarier	Noun	1 week ago	Progress bar
wein	Noun	1 week ago	Progress bar

Slika 23. Duolingo struktura i grafički prikaz sustava (izvor: autor disertacije)

Ribbon Hero 1 i 2 - dodatak je koji je razvio Microsoft kao potporu učenju Office alata. Jednom instaliran, pokreće se iz bilo kojeg potprograma kao što su PowerPoint, Excel ili Word, a korisnik se uključuje u izazove na temelju kojih može ostvariti **bodove**. Unutar platforme uključeno je praćenje korisnikova rada izvan sustava za učenje, čime se težina budućeg učenja prilagođava iako korisnik nije direktno povezan s obrazovnim sustavom. *Ribbon Hero* povezan je i s društvenim mrežama radi praćenja napredovanja drugih korisnika i dijeljenja informacija o uspješnosti i broju bodova.

ClassDojo - alat je za upravljanje nastavom usmjeren na **usredotočenost, disciplinu i ponašanje** polaznika. Svakom se polazniku dodjeljuje avatar koji je vidljiv ostalima. Na početku sata nastavnik postavi ciljeve, kao što su usredotočenost na zadatak, međusobno pomaganje, sudjelovanje u određenim aktivnostima i kada polaznik ostvari bilo koji cilj tijekom nastave, dodijeli mu se bod i povratna informacija, čime se utječe na **pozitivno ponašanje i usredotočenost**. Sustav je osmišljen za utjecaj na **intrinzičnu motivaciju**, a **avatar se mijenja** kako polaznik napreduje u obrazovnom procesu.

World Peace - predstavlja simulaciju u kojoj sudjeluje 30 igrača. Polaznici/igrači su podijeljeni u četiri do pet timova s **tajnim i globalnim zadacima** koji se razmatraju u simulaciji. U simulaciju je uključen aspekt **politike, društva, ekonomije i vojske**. Sudionici koriste **kognitivne sposobnosti i maštu** za rješavanje problema koji se zadaje na početku ili za vrijeme trajanja simulacije. Timovi traže suradnju i kooperaciju za postizanje vlastitih ciljeva, ali i za postizanje globalnog cilja koji je zadan na početku simulacije. Glavni cilj ovog gemifikacijskog alata je postizanje sklada i balansa u kompliciranim situacijama uz korištenje minimalnog broja vojnih intervencija.

Coursera - obrazovna tehnologija koja je povezana s nekim od najuglednijih sveučilišta kao što su Princeton, Michigan, Pennsylvania i Stanford. Cilj je omogućiti besplatne *online* nastavne materijale iz područja znanosti i *klasičnog* inženjerstva, pa sve do humanističkih i poslovnih domena. Lekcije su osmišljene u vidu **kratkih videa** o određenoj temi, a popraćene su s tjednim **zadacima** koji se mjere i ocjenjuju. Rezultati su trenutno vidljivi studentu i svim uključenim nastavnicima zbog komunikacije i povratne informacije. U sustavu su integrirani **bodovi, bedževi** i drugi načini **nagrađivanja**, kao i prelazak na lakše i teže **razine**. Interaktivnost između studenata usmjerena je na poticanje motivacije i usredotočenosti na proces učenja kroz gradnju **timova** ili **individualnog** rješavanja problemskih zadataka. Student u svakom trenutku vidi svoj napredak. Omogućena mu je samoanaliza rada i analiza razumijevanja nastavnih materijala. Zanimljivo je napomenuti da je najposjećeniji set tečajeva upravo onaj vezan uz **gemifikaciju obrazovanja**.

3.12. POSTOJEĆI PRIZNATI GEMIFIKACIJSKI MODELI

U ovom poglavlju navode se istraživači i njihovi prijedlozi modela za izradu *gemificiranih* sustava koji se mogu koristiti u obrazovne svrhe. Navode se principi i objašnjenja osnovnih motivacijskih elemenata. Poglavlje se zaključuje grafičkim prikazima te *Octalysis* analizom eRIOOS (elementi računalnih igara u online obrazovnom sustavu) modela.

Kim i Lee (2013.) u svom radu prikazuju *gemificirani dinamični model za učenje* (*DMGL*, eng. *Dynamical Model for Gamification of Learning*). Kim i Lee se referenciraju na Deterdinga i suradnike (2011.) koji su utemeljili model MDA (eng. *Mechanics, Dynamics, Aesthetics*). **Model MDA** temelji se na elementima mehanike, dinamike i estetike. Zichermann i Cunningham (2011.) su model MDA upotpunili **izazovima, maštom, kontrolom i znatiželjom**. Rezultat DMGL-a je sustav koji se uvelike razlikuje od tradicionalnog poučavanja. Kim i Lee (2013.) navode da je **obrazovna efikasnost** znatno niža u odnosu na tradicionalno poučavanje, ali taj pokazatelj vrijedi samo u početnim fazama poučavanja. Zaključuje se da je **potrebno vrijeme navikavanja i adaptacije**, nakon kojeg slijedi rapidno povećanje i nadilaženje efikasnosti tradicionalnog učenja.

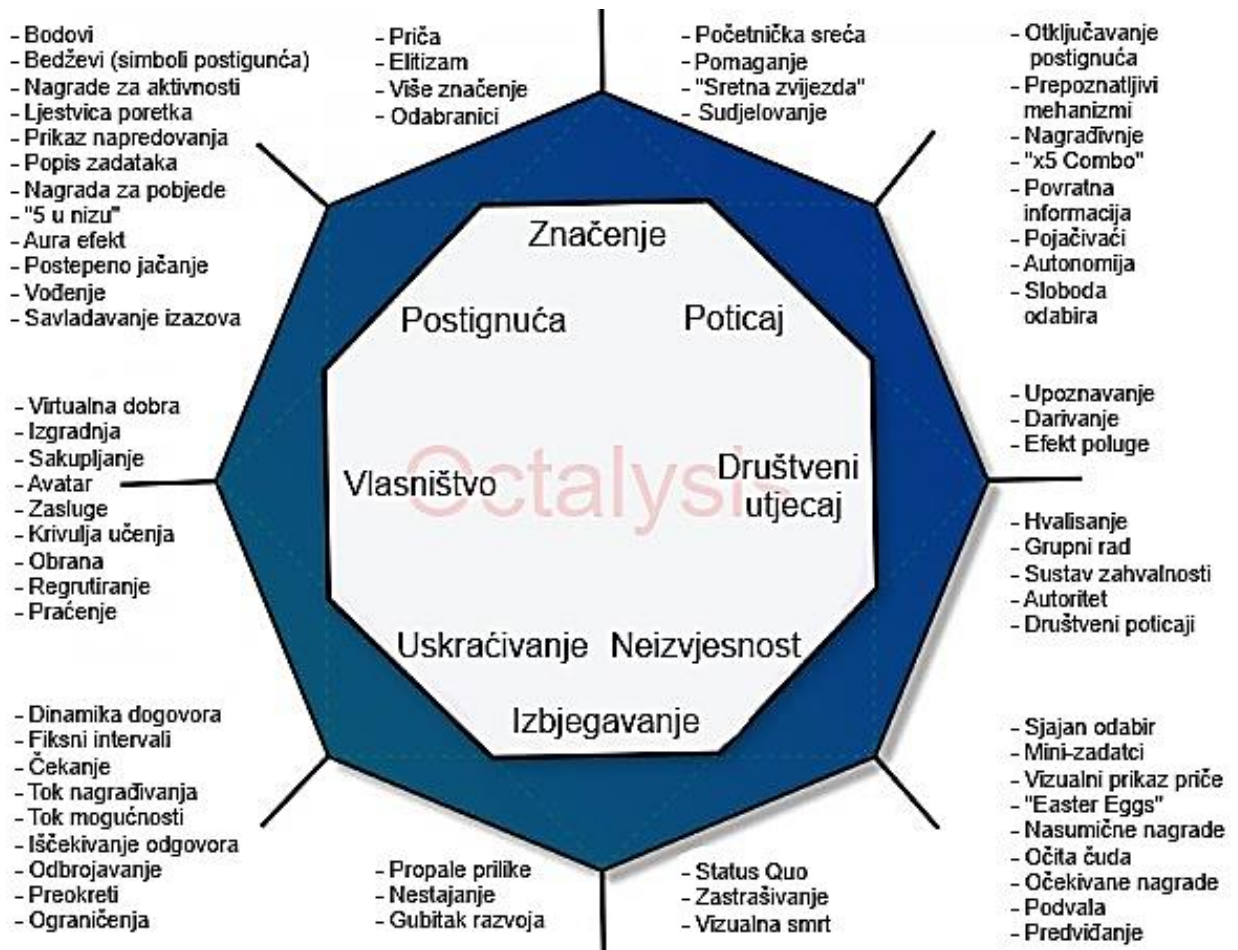
Carvalho i suradnici (2014.) predstavljaju u svom istraživanju model za gemificirane aktivnosti. Model uključuje neke od ključnih elemenata kao što su **sadržaj, zadaci, razine, povratne informacije, top-liste i sklonosti grupe**. Osim navedenih elemenata, predlaže se korištenje nagrada i kazni, vremenski ograničenih zadataka i pomoćnih cjelina koje su u funkciji skripti. Model predstavlja **niz poveznica i smjernica** u vidu neke vrste jednostavnog **dijagrama aktivnosti**. Model je teoretski prijedlog kako kreirati funkcionalnu cjelinu usmjerenu na poučavanje na **visokoškolskim institucijama**. Carvalho i suradnici (2014.) navedeno spominju kao sljedeći korak u njihovom istraživanju.

Ergle (2015.) u svojem istraživanju navodi korake o kojima bi se trebalo voditi računa prilikom planiranja i implementacije gemifikacije u poslovne sustave.

- **Identificiranje** ciljeva organizacije,
- **Identificiranje** glavnog cilja gemifikacijskog sustava,
- **Identificiranje** korisnika,
- **Identificiranje** sadržaja,
- **Dizajniranje i odabir** elemenata računalnih igara,
- **Definiranje** mjernih instrumenata
- **Definiranje** načina komunikacije
- **Praćenje** efikasnosti i usavršavanje sustava

Isti principi mogli bi se primijeniti i na obrazovne sustave.

Economou i suradnici (2015.) opisuju model pod nazivom *Octalysis* koji je razvio Y. Chou. Model *Octalysis* predstavlja sistematičan model koji stavlja u vizualan međuodnos gemificirane elemente određenog ustava. Model se temelji na pretpostavci da je gotovo svaka igra ili sustav koji se bazira na igri zabavan jer utječe na osnovne motivacijske osobine korisnika. Rezultat je poticanje unaprijed isplaniranih aktivnosti. Model *Octalysis* temelji se na **osam motivacijskih pokretača**, koji su, prema Chou (2016.), raspoređeni u oktogonalnom obliku kako je navedeno na slici 24.



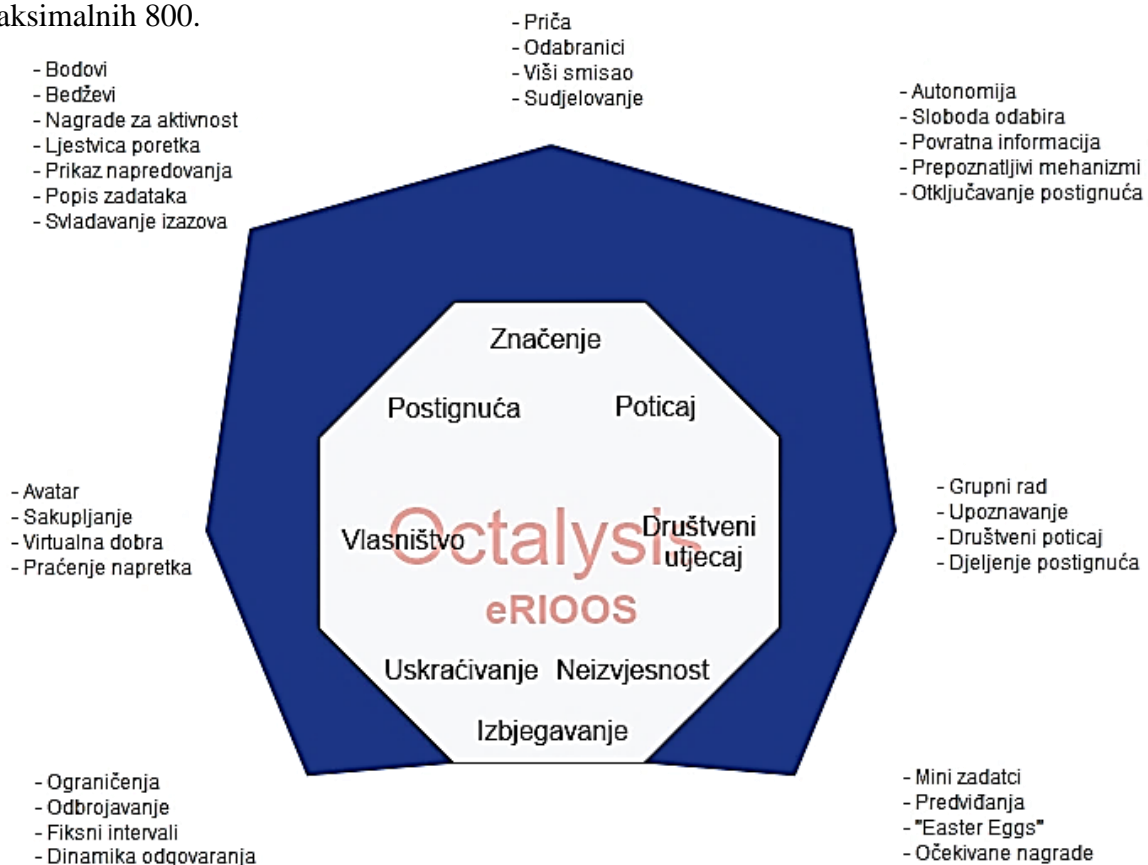
Slika 24. *Octalysis* sustav i osnovni elementi
(izvor: prilagođeno prema Economou, 2015.; Chou, 2016.)

Octalysis sustav sačinjen je od sljedećih motivacijskih elemenata:

- **Epsko značenje** - navodi da korisnik sustava vjeruje kako su njegove akcije važne. Kako su korisnikova aktivnost i on kao pojedinac važni za sustav.
- **Razvoj i nova postignuća** - predstavljaju unutarnji motivacijski proces koji kroz vrijeme, pojedinca dovodi do osobnog napretka, razvoja određenih vještina te na posljetku i do rješavanja određenih prepreka. Chou ističe kako je pojam izazova ovdje od iznimne važnosti.
- **Kreativnost i povratna informacija** - odnosi se na problemske situacije u kojima korisnik treba biti domišljat u prijedlogu rješenja. U navedenim scenarijima, pojedinac treba vidjeti na koji način se njegovo rješenje može uklopiti u postojeći scenarij, što se osigurava povratnim informacijama i podražajima iz *gemificiranog* sustava.
- **Vlasništvo** - kao četvrta komponenta *Octalysis* modela govori o intrinzičnoj motivaciji koja se javlja prilikom posjedovanja određene stvari ili pojma. Chou navodi da se kod korisnika, koji za nagradu dobije vlasništvo nad određenim predmetom, trenutno javlja želja za usavršavanjem i stjecanje novih dobara. Govori se o virtualnim elementima koji služe kao nagrada sustava za određeno postignuće ili za niz aktivnosti. Osjećaj vlasništva javlja se i kada korisnik ulaže dodatno vrijeme u personalizaciju profilne stranice, svojih postignuća ili avatara.
- **Društveni utjecaj i povezanost** - uključuje niz motivacijskih elemenata kao što su mentorstvo, međusobno prihvaćanje, kritičko promišljanje, suradnja, međusobno natjecanje i dr.
- **Uskraćivanje i nestrpljivost** - odnosi se na osjećaj koji se javlja kod korisnika uslijed želje za nečime što trenutno ne može imati. Funkcija se koristi prilikom otvaranja novih djelovah sustava ili nezadovoljavanja određenih kriterija.
- **Neizvjesnost i znatiželja** - odnosi se na skrivene dijelove priče ili sustava koji doprinosi krajnjim ciljevima sustava u vidu maštanja o mogućim aktivnostima polaznika.
- **Gubitak i izbjegavanje** - vidljivo je u situacijama gdje se želi minimizirati određeni loš događaj ili utjecaj koji doprinosi neželjenom krajnjem ishodu ili aktivnostima.

Elementi modela *Octalysis* koji se nalaze na desnoj strani slike 24. predstavljaju poticaj za **kreativnost, samoizražavanje i društvenost**. Ti elementi vezani su za intrinzičnu motivaciju, za razliku od elemenata na lijevoj strani, koji se odnose na ekstrinzičnu motivaciju. Elementi lijeve strane povezani su s **ciljevima, nagradama, dobrima** koji se mogu zaraditi ili osvojiti. Elementi koji se nalaze na vrhu sustava smatraju se **pozitivnim motivatorima** koji potiču usavršavanje znanja i vještina kroz smisao i razne poticaje. Elementi koji se nalaze na dnu sustava smatraju se **negativnim motivatorima** koji potiču lošu emociju te se trebaju minimizirati prilikom planiranja i implementiranja sustava.

Model **eRIOOS**, kojeg je autor ove disertacije kreirao pomoću alata za procjenu *gemificiranih* sustava *Octalysis*, vidljiv je na slici 25. Naglasak je u eRIOOS modelu stavljen na elemente koji se nalaze na vrhu sustava, što upućuje na pozitivan poticaj i emociju kod korisnika sustava. Mogući je nedostatak što korisnici nemaju **osjećaj hitnosti** za izvršavanje određene aktivnosti. Hitnost se može kontrolirati kategorijom "izbjegavanje" ako navedeno bude potrebno u budućnosti. Iz slike 25. vidljivo je da je postignut **balans između lijeve i desne** strane, koje predstavljaju **analitiku i kreativnost**. Balans predstavlja i dobru ravnotežu između **intrinzične i ekstrinzične** motivacije, gdje je potrebno biti vrlo oprezan jer ekstrinzični motivacijski elementi mogu lako nadvladati intrinzične. Rezultat sustava je **408 bodova** od maksimalnih 800.



Slika 25. eRIOOS model prikazan kroz *Octalysis Online* alat (izvor: autor disertacije)

Hendriks (2015.) citira podjelu Huang i Soman (2013.) koja je usmjerena na dizajniranje gemifikacijskog obrazovnog tečaja. Podjela je simplificirana i sastoji se od **pet koraka**.

- **Razumijevanje sadržaja i korisnika** – prvi korak u kojemu se administrator ili nastavnik gemifikacijskog sustava upoznaje s mogućim problemskim situacijama ovisno o nastavnim jedinicama i ciljanim skupinama polaznika e-tečaja.
- **Definiranje ciljeva** – odnosi se na bilo koji set elemenata koji mogu poboljšati znanje i motivaciju ili potaknuti promjenu u ponašanju polaznika e-tečaja. Ciljevi su usko povezani s ishodima učenja kojima se pristupa kao izazovima koji doprinose smisljenoj cjelini.
- **Strukturiranje iskustva** – sustav se analizira na dijelove s ciljem uočavanja koje su cjeline teže za polaznike e-tečaja, te se u tim cjelinama planira poseban korisnički poticaj. Poticajem se na pozitivan način utječe na motivaciju polaznika e-tečaja i nastavak učenja kroz bodove, certifikate, virtualne valute ili druge poticajne elemente.
- **Identificiranje resursa** – pod resursima se podrazumijeva bilo što je mjerljivo npr. bodovi, položene provjere znanja ili vrijeme. U ovoj fazi definiraju se pravila i povratne informacije koje se odnose na aktivnosti polaznika e-tečaja.
- **Određivanje elemenata** – zadnji korak je povezivanje pravila i resursa s obzirom na polaznike e-tečaja i nastavne cjeline. Odabrani *gemificirani* elementi trebaju biti dovoljno jasni i prihvaćeni od strane polaznika e-tečaja kako se ne bi stvorio suprotan efekt prilikom korištenja sustava. Neki od korištenijih elemenata iz računalnih igara su: *avatar, personalizacija sučelja, bonus materijali, formiranje timova, povratne informacije, nagrade, bodovi, virtualne valute i dućani, motivirajuća priča, transparentnost bodova sustava* i sl.

Werbach (2012.) predlaže model za razvoj *gemificiranog* sustava unutar ranije navedene knjige *For the Win: How Game Thinking Can Revolutionize Your Business*. Još se jednom može istaknuti model koji Werbach temelji na sljedećim koracima (vidjeti poglavlje 3.2.2.)

- osmisliti ciljeve i ishode sustave;
- opisati željena ponašanja;
- opisati korisnike sustava, igrače;
- osmisliti ponavljajuće aktivnosti;
- osmisliti elemente zabave;
- osigurati potrebne tehnološke preduvjete.

4. DIZAJN E-TEČAJA

U ovom poglavlju prikazani su rezultati ankete koja je provedena među **43 nastavnika** na visokoškolskoj instituciji u sjeverozapadnoj Hrvatskoj. Analizirane su karakteristike Moodle LMS sustava, kao i njegovi mogući *gemificirani* dodaci. Izrađen je konceptualni eRIOOS¹ model od strane autora ove disertacije. Poglavlje se zaključuje izradom idejnog rješenja eRIOOS *gemificiranog* e-tečaja.

4.1. ANALIZA ELEMENATA MOODLE E-TEČAJA NA VISOKOŠKOLSKIM INSTITUCIJAMA

Istraživački rad za pripremu *gemificiranih* tečajeva u okviru ove disertacije započeo je prikupljanjem mišljenja nastavnika koji koriste e-učenje i pregledom postojećeg stanja primjene Moodle e-tečajeva u visokom obrazovanju. Od nastavnika na jednoj visokoškolskoj instituciji prikupljena su ukupno 43 korektno popunjena obrasca s odgovorima na zadana pitanja. Svi ispitanici u svom kolegiju koristili su Moodle, a većina kolegija izvođena je na drugoj i trećoj godini studija. Najčešći je slučaj bio da nositelj kolegija u suradnji s asistentom uređuje e-kolegij, a komunikacija s administratorima sustava je minimalna. Na pitanje "Koristite li posebno prilagođeni grafički predložak?" odgovor je "Ne" ili "Nemamo izbora". Također, većina ispitanika (53%) nije bila upoznata sa sustavima *Khan Academy*, *DuoLingo* ili sličnim sustavom za e-učenje, što nije pozitivan pokazatelj jer su navedeni sustavi dobili ugledne nagrade i predstavljaju samo neke od inovativnih pristupa u online prenošenju znanja. Zanimljivo je isto tako da se kod odgovora o vanjskim servisima i poveznicama koje su mogle biti ugrađene u sustav LMS čak 58% odgovora anketiranih nastavnika odnosilo na "ništa od navedenog" (Facebook, Twitter, Yahoo, YouTube, Gmail, Gsearch, Wikipedija)

Sljedeći set pitanja bio je vezan uz slaganje s tvrdnjama, a zanimljivo je da većina ispitanika ne preferira analogne nastavne materijale, ali preferira statičan tekst koji je popraćen PPT prezentacijom ili PDF člankom. U Moodle LMS sustavu najkorišteniji su bili sljedeći obrazovni elementi ili aktivnosti:

1. Forum	(86%)	4. Multimedija	(58%)
2. Ostvareni trenutni bodovi	(67%)	5. Bonus nastavni materijali	(49%)
3. Upitnici	(65%)	6. Uređivanje profila, Avatar	(28%)

¹ Model eRIOOS je model prema kojemu je dizajniran *eksperimentalan* e-tečaj koji je razvio autor ove disertacije. eRIOOS je skraćena od elemenata računalnih igara u online obrazovnom sustavu

Aktivnosti koje studenti koriste u Moodle LMS sustavu su sljedeće:

1. Kvizovi i zadaci kreirani od strane nastavnika (53%)
2. Omogućavanje studentima davanje povratnih informacija nastavniku (53%)
3. Međusobna studentska suradnja na problemskim zadacima (26%)
4. Individualni dobrovoljni usputni zadaci (26%)
5. Mogućnost osnovne personalizacije korisničkog sučelja (14%)

Anketirani nastavnici slažu se s navodima kako priča i motivacijski elementi vidljivi u računalnim igrama mogu pozitivno utjecati na interes za nastavnu temu, ali isto mnogo ispitanika (49%) nisu bili upoznati s **teorijom tijeka** (eng. *flow theory*), dok ih je nešto manje (37%) bilo upoznato samo djelomično.

Slike 26. i 27. prikazuju Moodle sustave koje studenti koriste u razdoblju provođenja ovog istraživanja. Slike su kreirane direktnim snimanjem ekrana za vrijeme boravljenja u sustavima te su zbog toga i korigirane kako ne bi došlo do otkrivanja identiteta ili povrede autorskih prava. Korisničko iskustvo prilikom korištenja navedenih e-tečajeva ne daje dojam da su isti kreirani radi motiviranja korisnika, već da su kreirani iz nužde **popunjavanja online sustava Moodle nastavnim sadržajima** određenog kolegija. Raspored materijala nije konzistentan što može stvoriti osjećaj frustracije prilikom pretraživanja dokumenata i nastavnih sadržaja.

The screenshot displays a Moodle course interface. On the left, a sidebar contains navigation menus for 'Moja naslovnica', 'Postavke', 'Pretraži forume', 'Attendance', and 'Korisnici online'. The main content area is titled 'KONTINUIRANO PRAĆENJE (MODEL A - za redovite studente / opcionalan za izvanredne studente)' and lists various activities such as 'Bodovi - Pristustvovanje auditornim vježbama', 'Bodovi - Izrada zadataka na lab. vježbama', and 'Bodovi - 1. kolokvij'. Below this, there is a section for 'MODEL B (pismeni i usmeni ispit) - za izvanredne studente' with activities like 'Privremeno - predaja datoteka za izvanredne' and 'Bodovi (IZV) - Rješavanje zadataka laboratorijskih vježbi'. At the bottom, a section for 'NADOKNADA SEMINARSKIH RADOVA' is visible. On the right side, there are several widgets: 'Dodajte novu temu...', 'Calendar' for December 2015, 'Legenda' for activity icons, 'Slučajni odabir iz rječnika', and 'Nedavna aktivnost'.

Slika 26. Primjer dijela sadržaja Moodle e-tečaja "X"



Prijavljeni ste sustavu kao Bernik Andrija (Odjava)

• ▶ 3D-1415 Switch role to...
Omogući izmjene

Korisnici

Sudionici

Aktivnosti

Forumi
 Resursi

Pretraži forume

Kreni
Napredno pretraživanje

Administracija

- Omogući izmjene
- Postavke
- Assign roles
- Grupe
- Backup
- Restore
- Import
- Reset
- Reports
- Pitanja
- Skale
- Datoteke
- Ocjene
- Ispiši me iz kolegija 3D-1415
- Profil

Moji kolegiji

- Video animacija
- 3D modeliranje

- Reports
- Pitanja
- Skale
- Datoteke
- Ocjene
- Ispiši me iz kolegija 3D-1415
- Profil

Moji kolegiji

- Video animacija
- 3D modeliranje
- Video animacija
- 3D modeliranje
- 3D modeliranje
- Video animacija

Svi kolegiji...

Tjedni pregled

Forum s vijestima

2.03.2015 - 8.03.2015
- Sustav -

- Ishodi učenja kolegija 3DM
- Dobrodošli u sustav 3DM
- Video - Maya Learning Channel
- Poglavlje - Uvod u Mayu 2014

9.03.2015 - 15.03.2015
Maya - 3D modeliranje

- Ishodi učenja kolegija 3DM
- Forum - 3D modeliranje
- Video - Maya 2015 alati
- Video - Osnove 3D Modeliranja
- Video - Rupe u modelu!?
- Poglavlje - Poligonarno modeliranje
- Bonus - Coca-Cola 3D čep
- Video - NURBS modeliranje
- Poglavlje - NURBS modeliranje
- Bonus - 3D Character Art za igre

16.03.2015 - 22.03.2015
Maya - Materijali i Teksturiranje

- Ishodi učenja - Teksturiranje
- Forum - Teksturiranje
- Video - Materijali i sjenčanje 1
- Video - Materijali i sjenčanje 2
- Poglavlje - Materijali
- Poglavlje - Sjenčanje
- Video - UV mapiranje 1
- Video - UV mapiranje 2
- Bonus - 3D Character Art za igre

16.03.2015 - 22.03.2015
Maya - Materijali i Teksturiranje

- Ishodi učenja - Teksturiranje
- Forum - Teksturiranje
- Video - Materijali i sjenčanje 1
- Video - Materijali i sjenčanje 2
- Poglavlje - Materijali
- Poglavlje - Sjenčanje
- Video - UV mapiranje 1
- Video - UV mapiranje 2
- Video - UV mapiranje 3
- Poglavlje - UV mapiranje
- Video - Teksturiranje 1
- Video - Teksturiranje 2
- Poglavlje - Teksturiranje i osvjetljenje
- Bonus - BBC: Usporedba olovke i piksela

23.03.2015 - 29.03.2015
Maya - Osvjetljenje i renderiranje

- Ishodi učenja - Osvjetljenje i renderiranje
- Forum - Osvjetljenje i renderiranje
- Video - Osnove osvjetljenja
- Video - Indirect Light 1
- Video - Indirect Light 2
- Poglavlje - Osvjetljenje i renderiranje
- Bonus - Life after PI
- Video - Osvjetljenje i renderiranje
- Video - Mental Ray
- Video - Maya i Keyshot
- Poglavlje - Maya Software
- Bonus - IBL
- Bonus - Renderiranje u slojevima
- Poglavlje - Mental ray

30.03.2015 - 5.04.2015

Najsvježije vijesti

Dodajte novu temu...
(No news has been posted yet)

Buduća događanja

Nema predstojećih događaja

Prikaži kalendar...
Novi događaj...

Prijavljeni ste sustavu kao Bernik Andrija (Odjava)

Slika 27. Primjer dijela sadržaja Moodle e-tečaja "Y"

4.2. ELEMENTI RAČUNALNIH IGARA PRIMJENJIVI NA MOODLE PLATFORMI

U ovom poglavlju navodi se verzija Moodle platforme i korišteni dodaci (eng. *plugins*) pomoću kojih su kreirani e-tečajevi ovog istraživanja. Slijedi popis elementa računalnih igara koji su namijenjeni za *eksperimentalne* grupe ovog istraživanja, a time se poglavlje i završava.

Za potrebe istraživačkog rada korišten je računalni poslužitelj na kojemu su instalirani odvojeni Moodle e-tečajevi koji su upotpunjeni elementima računalnih igara, vidljivi u tablici 24. Instalirana verzija **Moodle sustava je 2.7.**, koja u trenutku provođenja istraživanja podržava 1137 eksternih dodataka. Svih 1137 dodataka je prije samog odabira i implementacije u *gemificirani* Moodle sustav na odvojenom poslužitelju, pogledano i uspoređeno s mehanikom i dinamikom računalnih igara o kojima je bilo riječi u ranijem poglavlju. Neki od dodataka navedeni su u tablici 24.

Tablica 24. Elementi računalnih igara namijenjeni za *eksperimentalnom* e-tečaju

Simplificirano grafičko sučelje	Dinamično grafičko sučelje	Priča kao uvod u e-tečaj	Epsko značenje	Avatar, osobne informacije	Društvene mreže i Web usluge
Vizualan prikaz svih obveza	Zadaci i izazovi	Sakupljanje bodova	Napredovanja unutar e-tečaja	Sakupljanje bedževa	Status završenosti e-tečaja
Sinkrona komunikacija Chat	Asinkrona komunikacija Forum	Nelinearno korištenje nastavnih materijala	Zajednička kolaboracija	Interaktivno ponavljanje i provjera znanja	Top lista i poredak studenata
Otkrivanje sustava i nastavnih materijala	Elementi iznenađenja unutar e-tečaja	Uvjetovani pristup nastavnim materijalima	Odbrojavanje vremena	Povratne informacije	Edukativne igre GBL

Dodacima koji su uključeni u *gemificirani* sustav utječe se na mehaniku računalnih igara i na vizualan dojam sustava radi stvaranja zanimljivog virtualnog prostora te stvaranja preduvjeta za pozitivan utjecaj na motivaciju studenata. Detaljnije razmatrani Moodle vanjski dodaci prikazani su u tablici 25. Valja napomenuti da nisu svi dodaci koji su navedeni u tablici 25. mogu biti ugrađeni u *gemificirani* sustav zbog redundantnosti ili nekompatibilnosti s Moodle 2.7. verzijom LMS sustava.

Tablica 25. Moodle eksterni dodaci (eng. *plugins*) koji su potencijalno pogodni za korištenje u *eksperimentalnom e-tečaju* (izvor: autor disertacije)

Br.	Naziv dodatka	Svrha	Kategorija
1	mod_checklist_moodle27_2014080601	evidencija aktivnosti	Aktivnosti
2	mod_attendance_moodle27_2014050900	evidencija dolazaka	
3	mod_engagement_moodle27_2014042902	praćenje uključenosti	
4	mod_game_moodle27_2014071317	edukativne igre	
5	mod_choicegroup_moodle27_2014072101	odabir grupe	
6	mod_quizgame_moodle27_2014091101	postavljanje kviza	
7	mod_certificate_moodle27_2014051200	dodjela certifikata	
8	mod_simplecertificate_moodle27_2014070500	dodjela certifikata	
9	block_xp_moodle27_2014091100	evidencija bodova	Blokovi
10	block_exaport_moodle27_2014090500	ePortfolio alternativa	
11	block_progress_moodle27_2014072900	praćenje napretka	
12	block_fbcomments_moodle27_2014072100	Facebook dodatak	
13	block_checklist_moodle27_2014090800	evidencija aktivnosti	
14	block_timestat_moodle27_2014090401	vremensko ograničenje	
15	block_engagement_moodle27_2014042900	praćenje uključenosti	
16	block_workflow_moodle27_2014051400	upravljanje e-tečajem	
17	gradeexport_checklist_moodle27_2012070700	izvještaj za ocjene	Izvještaji
18	report_editgroups_moodle27_2014011700	izvještaj za grupe	
19	report_mygrades_moodle27_2014080400	izvještaj za ocjene	
20	report_overviewstats_moodle27_2014082200	izvještaj za status	
21	report_workflow_moodle27_2014051400	izvještaj za upravljanje	
22	report_overviewstats_moodle27_2014082200	izvještaj za upravljanje	
23	report_forumgraph_moodle27_2014072100	izvještaj za forum	
24	theme_elegance_moodle27_2014082100	predložak za dizajn	Dizajn korisničkog sučelja
25	theme_decaf_moodle27_2014010606	predložak za dizajn	
26	theme_essential_moodle27_2014090303	predložak za dizajn	
27	theme_rocket_moodle27_2014082300	predložak za dizajn	
28	theme_evolved_moodle27_2014051200	predložak za dizajn	

4.3. OPIS ELEMENATA RAČUNALNIH IGARA ODABRANIH ZA ISTRAŽIVANJE

Unutar tablice 24. koja nosi naziv "Elementi računalnih igara namijenjeni *eksperimentalnom* e-tečaju", navode se 24 elemenata računalnih igara koji su korišteni za oblikovanje *eksperimentalnih* e-tečaja u ovom doktorskom radu. U nastavku ove disertacije bit će objašnjeni svi ranije spomenuti elementi računalnih igara, uz navođenje osobina i postavki. Također, kako su ih studenti stjecali odnosno koristili. Potrebno je napomenuti kako nemaju svi elementi istu funkciju, niti su svi dostupni studentima za korištenje ili stjecanje.

- ❖ **Simplificirano grafičko sučelje:** Simplificirano grafičko sučelje odnosi se na estetski dizajn e-tečaja gdje se uklanjaju sve suvišne informacije, aktivnosti ili popratni blokovi. E-tečaj je podijeljen u dvije cjeline. **Prva cjelina** predstavlja općeniti dio u kojem student može vidjeti sve obveze i moguće aktivnosti koje je nastavnik kreirao unutar e-tečaja. U ovoj cjelini nalazi se uvod u e-tečaj koji je pisan u obliku poticajne priče. Studentima je osigurano nekoliko komunikacijskih mehanizama poput chata ili foruma. Unutar istog dijela nalazi se objašnjenje *gemificiranih* elemenata i objašnjenje načina rada u e-tečaju. **Druga cjelina** predstavlja specifični dio koji se odnosi na nastavne sadržaje e-tečaja. Sadržaj je estetski grupiran, posložen prema prioritetima što znači da su nastavni materijali na prvom mjestu, provjere znanja i edukativne igre na drugom mjestu, a bonus nastavni materijali na trećem mjestu. Glavna ideja je iskoristiti ekran što je više moguće, pri čemu se količina kretanja vertikalnim klizačem smanjuje na minimum. (*Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija"*).
- ❖ **Dinamično grafičko sučelje:** Dinamično grafičko sučelje omogućuje studentu korištenje padajućeg izbornika unutar kojega se nalaze sljedeće kategorije: Profil, Kalendar, Poruke, Bedževi, Privatne datoteke i Odjava iz sustava. Drugi padajući izbornik aktivan je onda kada student prati više e-tečajeva, čime je prolazak s jednog e-tečaja na drugi brži i jednostavniji. Uz to student može svaki grafički element u e-tečaju priključiti alatnoj traci koja se, ovisno o položaju miša, pojavljuje ili sakriva. Studentima je na raspolaganju i nekoliko interaktivnih grafičkih elemenata koji se odnose na naziv i tip aktivnosti koje je student završio ili će tek biti studentu na raspolaganju. Uz navedeno nalazi se i interaktivni prostor iz kojeg je vidljivo stanje tj. status završenosti određene aktivnosti. (*Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija"*).

- ❖ **Priča kao uvod u e-tečaj:** Priča kao uvod u e-tečaj predstavlja element koji kod studenta izaziva znatiželju. Usmjerena je na intrinzičnu motivaciju i osmišljena je tako da se studenta potakne na razmišljanje i aktivno djelovanje. Priča nema kraj, ali ima jasnu poruku. Zadnji elementi u priči sakriven je unutar EAN koda koji se treba skenirati mobilnim uređajem kako bi se prikazala poticajna slika koja studentov misaoni proces stavlja u prvi plan. Tekst priče koji se nalazi u **prvom glavnom istraživanju** glasi:

"Dobrodošao korisniče!

Preostalo nam je još samo 336 sati kako bi ti i tvoj tim napravili promjenu u G-Sustavu!

Ono što nam je potrebno jest vođa! "Master Blaster!" koji će svojim znanjem biti dugo iščekivano rješenje projekta!

Pridružit će ti se i nekoliko "Core Analyzer" i "Core Designer" pojedinaca u prolasku kroz sustav.

Pažljivo prati i uči na svom putu, postani pokretač i ne obaziri se na smetnje na koje i onako ne možeš utjecati.

G-Sustav je strogo čuvan projekt koji se razvija unutar zidina u potkrovlju.. xyxcz.. ovaj kanal više nije siguran..

Ti si prisutan sada.. i sada je sve što je potrebno.

Vremena je malo.. bitno je da imamo 1 cilj - 1 sustav - 336 sati.. "



Slika 28. Skrivena ilustracija iz *eksperimentalnog e-tečaja* (prilagođena prema Ortiz, 2016.)

(Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "Programiranje 2" i "Računalom posredovana komunikacija").

- ❖ **Epsko značenje:** Epsko značenje odnosi se na nevidljivi element e-tečaja koji kod studenta ostavlja dojam važnosti i povezanosti s nečim većim od samog nastavnog predmeta. Ideja u kojoj su studenti u mogućnosti utjecati na promjene u obrazovnom sustavu je jedan takav primjer. (*Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "Programiranje 2" i "Računalom posredovana komunikacija"*).

- ❖ **Avatar, osobne informacije:** Avatar predstavlja prostor u kojemu student postavlja svoju profilnu sliku. Osobne informacije uključuju lokaciju studenta, osobne interese i načine preferirane komunikacije kao i adresu elektroničke pošte. Unutar osobnog prostora nalaze se i svi bedževi koji su studentu dodijeljeni. (*Korišteno u oba e-tečaja u kolegijima "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija"*).

- ❖ **Društvene mreže i web usluge:** Društvene mreže odnose se na poveznicu koja je usmjerena prema jednoj od najpopularnijih mreža u trenutku provođenja ovog istraživanja, a to je *Facebook*. Sama poveznica uključena je u dizajn e-tečaja te ima dodijeljen središnji prostor koji je aktivan cijelo vrijeme, bez obzira na razinu ili aktivnost studenta. Web usluge vezane su za drugi dio središnjeg prostora koji je ugrađen u dizajn e-tečaja te je vezan za direktan pristup elektroničkoj pošti. Obje poveznice nalaze se na donjem dijelu grafičkog sučelja e-tečaja te se prema potrebi mogu ukloniti ili proširiti s drugim elementima. (*Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija"*).

- ❖ **Vizualan prikaz svih obveza:** Vizualan prikaz svih obveza osigurava slika svih aktivnosti kroz koje student može izučavati nastavnu cjelinu. Do svih aktivnosti postojao je direktan pristup putem poveznica čime se ostavlja dojam interaktivnog indeksa e-tečaja. Moguće je upisati i popratni tekst s napomenama kada se određene aktivnosti trebaju završiti ili kada će određene aktivnosti biti vidljive u sustavu. Uz navedeno, prikazuju se i edukativne računalne igre, kao i bonus nastavni materijali, te postotni izračun završenosti e-tečaja. (*Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija"*).

- ❖ **Zadaci i izazovi:** Zadaci i izazovi su aktivnosti koje su uvjetno omogućene studentu kako bi kroz njih mogao provjeravati znanje. Postoje dvije provjere znanja do kojih nije moguće doći sve dok se ne osiguraju uvjeti pregledavanja nastavnih materijala, interaktivnog korištenja komunikacijskih kanala i sl. Zadaci su postavljeni nakon nastavne cjeline, te se

odnose na pojmove ili logičke zadatke iz ranije navedenog područja. Svaka sljedeća provjera znanja sadrži teža pitanja čime se usporava prolazak kroz sustav. Provjera znanja ima vremensko ograničenje te je studentu osigurana trenutna povratna informacija o točnim odgovorima, kao i ocjena s obzirom na točne odgovore. Efekt izazova postignut je težinom pitanja i vremenskim ograničenjem za odgovaranje. Nakon provjere znanja, student može pristupiti edukativnoj računalnoj igri u kojoj se usvajaju ili ponavljaju pojmovi iz kolegija. (Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija").

- ❖ **Sakupljanje bodova:** Sakupljanje bodova je dodatak koji studentu pridodaje bodove ovisno o njegovoj aktivnosti u e-tečaju. Bodovi se raspoređuju prema unaprijed definiranom algoritmu koji autor disertacije nije mijenjao. Ako student kreira određeni sadržaj dobit će 45 bodova, ako čita određeni sadržaj dobit će 9 bodova te ako ažurira određeni sadržaj dobiti će 3 boda. Maksimalan broj bodova je ograničen i moguće ga je postići. U slučaju ovog istraživanja, bodovi nisu vezani za ocjenu studenta, ali bi se navedena mogućnost mogla u budućnosti implementirati uz pažljivu analizu sustava ocjenjivanja. (Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija").
- ❖ **Napredovanja unutar e-tečaja:** Napredovanja unutar e-tečaja predstavljaju vizualan dodatak dizajnu e-tečaja, gdje se ovisno o broju sakupljenih bodova dodjeljuju razine u sustavu. U *eksperimentalnom* e-tečaju kreirano je ukupno 15 razina od kojih je samo 8 nosilo posebna imena i to "Level 3: Keep it up!", "Level 4: Double klik!", "Level 5: Triple Klik!", "Level 6: Ownage!", "Level 7: Rampage!", "Level 10: Ultra klik!", "Level 12: God like :) !" i "Level 15: Beyond God like :) !!". Svaka razina ima određeni broj bodova gdje se računanje svodi na sljedeću formulu: $Razina X = ((ukupni\ bodovi\ razine\ X-1) * 1.3) + 120$; gdje je 1.3 koeficijent algoritma, a 120 baza algoritma. Obje vrijednosti mogu se mijenjati ako studenti prebrzo prolaze kroz razine. (Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija").
- ❖ **Sakupljanje bedževa:** Sakupljanje bedževa predstavlja dodatak koji je vezan za aktivnost studenta nad nastavnim materijalima i ostalim aktivnostima koje je uvjetovao nastavnik. U *gemificiranom* e-tečaju *prvog* i *drugog glavnog istraživanja* definirano je pet bedževa, pod nazivima koje je smislio autor ovog rada, te glase:

"**Level 1 - CR Core Reader**", "**Level 2 - CD Core Designer**", "**Level 3 - CA Core Analyzer**", "**Level 4 - CA Core Architector**" i "**Level 5 - MB Master Blaster!**". Svaki bedž predstavlja nagradu koju je student zavrjedio svojom aktivnošću u e-tečaju. Bedževi su dio vizualnog dizajna e-tečaja te se do istih može doći i kroz padajući izbornik sustava. Bedževi mogu biti trajni ili mogu postati nevažeći ovisno o pravilima pod kojima su ostvareni. Bedževi se mogu preuzeti na računalo ili ostaviti unutar osobnog prostora studentovog profila. Pravila, uvjete i nazive bedževa kreirao je autor ovog istraživanja s ciljem pozitivnog utjecaja na motivaciju studenata. U nastavku poglavlja navode se uvjeti za postizanje određenog bedža kako slijede:

❖ **Level 1 - CR: Core Reader** (početnik u sustavu)

Navedene aktivnosti trebaju biti završene:

"Ishodi učenja"

"Objašnjenje elemenata i načina s radom u e-tečaju (pročitati!)"

"Popis pojmova"

Level 2 - CD: Core Designer (dizajner sustava)

Navedene aktivnosti trebaju biti završene:

"Poglavlje 1a - Hrpa"

"Poglavlje 2a - Punjenje i Implementacija hrpe pomoću polja"

"Poglavlje 3a - Brisanje korijena i Implementacija hrpe pomoću cjelobrojnog polja"

"Poglavlje 4a - Punjenje hrpe"

"Poglavlje 5a - Uzastopno brisanje korijena hrpe (Heapsort)"

❖ **Level 3 - CA: Core Analyzer** (analist sustavu)

Navedene aktivnosti trebaju biti završene:

"Poglavlje 1b - Stog"

"Poglavlje 2b - Dodavanje (PUSH), očitavanje i brisanje vrha stoga (POP)"

"Poglavlje 3b - Ispis cijelog i dealokacija stoga"

Level 4 - CA: Core Architector (arhitekt sustava)

Navedene aktivnosti trebaju biti završene:

"Checkpoint +< 1 >+"

"Crossword - Programiranje A"

"Checkpoint +< 2 >+"

"Crossword - Programiranje B"

❖ **Level 5 - MB: Master Blaster!** (voditelj sustava)

Navedene aktivnosti trebaju biti završene:

"Bonus - Stari i novi nazivi standardnih biblioteka jezika C++"

"Bonus - Odnos između jezika C i C++"

(Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "Programiranje 2" i "Računalom posredovana komunikacija").

- ❖ **Status završenosti e-tečaja:** Status završenosti e-tečaja grafički je element dizajna e-tečaja koji se nalazi odmah ispod naziva e-tečaja. Student u svakom trenutku ima na raspolaganju vizualan prikaz obveza u e-tečaju. Bez obzira na dio sustava u kojem se student nalazi, status završenih nastavnih i nenastavnih aktivnosti, naziv i postotak završenosti e-tečaja uvijek su vidljivi. Status završenosti može se iskoristiti kao pokretač proaktivnosti jer studentu pokazuje koliko je blizu određenog cilja, bila to provjera znanja ili završetak e-tečaja. *(Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija").*

- ❖ **Sinkrona komunikacija - Chat:** Sinkrona komunikacija, odnosno Chat je aktivnost koju studenti imaju na raspolaganju. Moguće je ostvariti komunikaciju student-student ili student-nastavnik e-tečaja. Za navedenu aktivnost potrebno je stvoriti poticajnu situaciju u kojoj bi studenti vidjeli važnost sudjelovanja i kako bi bili prisutni i aktivni u određenom trenutku. Chat predstavlja iznimno veliku važnost unutar društvenih mreža, te se može koristiti za virtualne sastanke u okviru elementa "Priče". *(Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "Programiranje 2" i "Računalom posredovana komunikacija").*

- ❖ **Asinkrona komunikacija - Forum:** Asinkrona komunikacija, odnosno Forum je aktivnost koja je povezana s nastavnim materijalima gdje studenti međusobno imaju mogućnost dijeliti zanimljivosti vezane uz nastavni sadržaj. Ako se potiče javna rasprava i razmjena nastavnih materijala, ali ujedno i nagrađuje željena aktivnost studenata, postiže se vrijedan repozitorij znanja koje studenti mogu koristiti kao prošireni nastavni sadržaj. U navedenom slučaju, nastavnik u e-tečaju ima i ulogu administratora koji će trebati filtrirati i/ili voditi raspravu u određenom smjeru, kako bi se očuvao obrazovni smisao takve aktivnosti. *(Korišteno u oba e-tečaja u kolegijima "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija").*

- ❖ **Nelinearno korištenje nastavnih materijala:** Nelinearno korištenje nastavnih materijala osigurava studentu odabir nastavne cjeline po želji. Student ne treba slijediti poglavlje po poglavlje, već može pristupiti poglavlju koje mu se u danom trenutku sviđa. Ovo je posebno koristan element u slučaju gemificiranja cijelog kolegija. Valja napomenuti kako nastavnik ili administrator sustava treba omogućiti višestruki odabir nastavnih sadržaja ili poglavlja kako bi student imao osjećaj autonomije. Međutim, poglavlja koja se mogu odabrati trebaju biti rangirana prema važnosti ili složenosti, te ih treba prezentirati studentu kroz pravila korištenja sustava kako se ne bi dogodilo višestruko preskakanje nastavnih materijala.

Student neće moći dohvatiti ili pristupiti svim elementima sustava zato što je za neke dijelove sustava potrebno zadovoljiti određene kriterije. (*Korišteno u oba e-tečaja u kolegijima "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija"*).

- ❖ **Zajednička kolaboracija:** Zajednička kolaboracija ostvarena je kroz epsko značenje i pripadnost grupi, te kroz asinkronu i sinkronu komunikaciju. Studenti su kroz priču uvedeni u sustav koji ovisi o njihovim akcijama i aktivnostima čime se stvara osjećaj povezanosti unutar jedne grupe. Kroz Chat i Forum može se dijeliti znanje i zanimljivosti vezane uz nastavne materijale. Studenti mogu sudjelovati u izradi ispitnih pitanja odnosno izazova kroz popunjavanje rječnika pojmova koji potom mogu biti povezani s edukativnim računalnim igrama. Ako se edukativne računalne igre koriste, dobro ih je pozicionirati nakon svakog poglavlja. (*Korišteno u e-tečaju samo za eksperimentalnu skupinu iz "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija"*).
- ❖ **Interaktivno ponavljanje i provjera znanja:** Interaktivno ponavljanje i provjera znanja osigurani su kroz višestruki pristup zadacima i izazovima koji su ograničeni količinom pitanja i vremenom koje student ima na raspolaganju. Studentu se može omogućiti višestruki pristup zadacima, no pristup se može i ograničiti prema potrebi. U slučaju ovog doktorskog rada, studenti *prvog* i *drugog glavnog istraživanja* imali su neograničen pristup pitanjima za ponavljanje nastavne cjeline. (*Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "Programiranje 2" i "Računalom posredovana komunikacija"*).
- ❖ **Top lista i poredak studenata:** Top lista i poredak studenata osiguravaju transparentnost sustava, čime se studenti mogu međusobno uspoređivati, te mogu provjeravati što su drugi kolege u međuvremenu ostvarili ili napravili. Top lista i poredak studenata vezani su uz gemificirane elemente sustava poput: "Sakupljanje bodova" i "Napredovanje unutar e-tečaja". Nakon odabira prikaza poretka, prikazuje se padajući poredak svih studenata sa dostignutim razinama i dodijeljenim bodovima. Također, vidljivi su i svi osvojeni bedževi koje svaki student posjeduje, čime se automatski zna koje su aktivnosti u e-tečaju studenti završili. (*Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija"*).

- ❖ **Otkrivanje sustava i nastavnih materijala:** Otkrivanje sustava predstavlja dio dizajna e-tečaja gdje se u određenom trenutku dogode promjene u e-tečaju (tzv. *Easter Eggs*) koje svi studenti neće odmah uočiti. Zanimljivost se podiže činjenicom kako je u *eksperimentalnom* sustavu skriveni dio sustava bio vidljiv samo 24 sata. U tom periodu se pojavila poruka koja je izgledala kao podsjetnik na datum kada se piše završna provjera znanja. Automatski se unutar foruma pojavila i poruka: "Jeste li pronašli skriveni element u sustavu?". Nastavni materijali koji se postepeno otkrivaju studentima, predstavljaju promjenu u e-tečaju koja se događa prema unaprijed definiranom planu s ciljem poticanja znatiželje kod polaznika e-tečaja. (*Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija"*).

- ❖ **Elementi iznenađenja unutar e-tečaja:** Elementi iznenađenja unutar e-tečaja odnose se na nenajavljene promjene u sustavu, usputne osobne poruke u skrivenim dijelovima e-tečaja, te na grafičke elemente koji služe za informiranje ili motiviranje studenata za još većim korištenjem elemenata e-tečaja. (*Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija"*).

- ❖ **Uvjetovani pristup nastavnim materijalima:** Uvjetovani pristup nastavnim materijalima vezan je za "Bonus nastavne materijale", pristup pitanjima za ponavljanje znanja, te pristup edukativnim igrama. Unutar sustava postojao je precizan skup aktivnosti koje je bilo nužno zadovoljiti kako bi se određeni dijelovi sustava otključali. Studentima je navedeno pojašnjeno unutar prve cjeline e-tečaja kroz forum dobrodošlice. (*Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija"*).

- ❖ **Odbrojavanje vremena:** Odbrojavanje vremena je funkcija koja je uključena u aktivnostima za ponavljanje i provjeru znanja, koje broje 13 pitanja za prvu nastavnu cjelinu i 10 pitanja za drugu nastavnu cjelinu, uz vremensko ograničenje od pet minuta. (*Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "Programiranje 2" i "Računalom posredovana komunikacija"*).

- ❖ **Povratne informacije:** Povratne informacije automatski su generirane prilikom određene studentove aktivnosti. Osim vizualne promjene u obliku bedža, kvačice ili zelene kućice, sustav oko važnijih aktivnosti informira studenta osobnom porukom i to za osvajanje novog bedža, napredovanje na novi nivo ili za komunikaciju u koju je student uključen.

Sve osobne poruke nalaze se unutar padajućeg izbornika ili u profilnom prostoru studenta. (Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "3D modeliranje", "Programiranje 2" i "Računalom posredovana komunikacija").

- ❖ **Edukativne igre GBL:** Edukativne igre (eng. *Gema Based Learning, GBL*) odnose se na križaljku koja je standardna igra unutar Moodle okruženja. Igra je povezana s pojmovima koji su izučavani unutar *prvog* i *drugog glavnog istraživanja* koji su uneseni iz osnovne literature za odabrane kolegije. Osim ove igre postoji niz drugih koje se mogu uključiti u e-tečaj prema potrebi. (Korišteno u e-tečaju samo za eksperimentalnu skupinu iz kolegija "Programiranje 2" i "Računalom posredovana komunikacija").

Tablica 26. Usporedni prikaz elemenata računalnih igara koji su korišteni u sva tri istraživanja

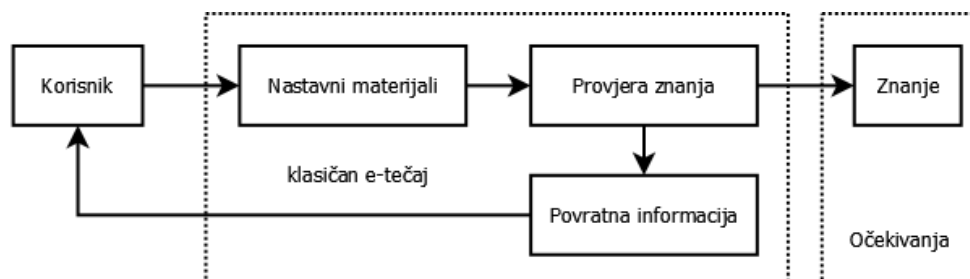
<i>Element računalnih igara</i>	<i>Predistraživanje</i>		<i>Prvo glavno istraživanje</i>		<i>Drugo glavno istraživanje</i>	
	<i>E*</i>	<i>K*</i>	<i>E*</i>	<i>K*</i>	<i>E*</i>	<i>K*</i>
Simplificirano grafičko sučelje	+		+		+	
Dinamično grafičko sučelje	+		+		+	
Priča kao uvod u e-tečaj			+		+	
Epsko značenje			+		+	
Avatar, osobne informacije	+	+	+	+	+	+
Društvene mreže i web usluge	+		+		+	
Vizualan prikaz svih obveza	+		+		+	
Zadaci i izazovi	+		+		+	
Sakupljanje bodova	+		+		+	
Napredovanja unutar e-tečaja	+		+		+	
Sakupljanje bedževa			+		+	
Status završenosti e-tečaja	+		+		+	
Sinkrona komunikacija Chat			+		+	
Asinkrona komunikacija Forum	+	+	+	+	+	+
Nelinearno korištenje nastavnih materijala	+	+	+	+	+	+
Zajednička kolaboracija	+		+		+	
Interaktivno ponavljanje i provjera znanja			+		+	
Top lista i poredak studenata	+		+		+	
Otkrivanje sustava i nastavnih materijala	+		+		+	
Elementi iznenađenja unutar e-tečaja	+		+		+	
Uvjetovani pristup nastavnim materijalima	+		+		+	
Odbrojavanje vremena			+		+	
Povratne informacije	+		+		+	
Edukativne igre / GBL			+		+	

*E = eksperimentalan tečaj, K = kontrolni tečaj

4.4. IZRADA I IMPLEMENTACIJA IDEJNOG RJEŠENJA

U ovom poglavlju prikazuje se pojednostavljen model *klasičnog* e-tečaja te način na koji su provedene osnovne aktivnosti u nastavnom procesu. Slijedi slika konceptualnog *gemificiranog* modela pod nazivom eRIOOS² kojeg je kreirao autor ove disertacije. Na temelju modela eRIOOS razvija se detaljni prikaz i idejno rješenje *gemificiranog* e-tečaja (za eksperimentalne istraživačke skupine) unutar Moodle platforme. Poglavlje završava prikazima konkretnih *gemificiranih* e-tečaja koji su korišteni u ovom istraživačkom radu.

U skladu s istraživačkim hipotezama napravljena je analiza ispitanika te je proveden odabir ispitanika u skladu s načelima znanstvenoistraživačkog rada. Odabrano se vrijeme provođenja eksperimenta te intervali u kojima su ispitanici upoznati s obvezama i mogućnostima istraživanja. Ispitanicima se nije govorilo ništa što bi moglo narušiti ispravnost u kasnijim mjerenjima. Vrijeme provođenja istraživanja definiralo je i nastavnu cjelinu s obzirom na to kako je istraživački rad proveden tijekom akademske godine. Za odabranu nastavnu cjelinu bilo je potrebno je definirati ishode učenja, kao i nastavne sadržaje za klasične i *eksperimentalne* e-tečajeve u sva tri istraživanja. Teoretski pojednostavljen model *klasičnog* e-tečaja prikazan je na slici 29.



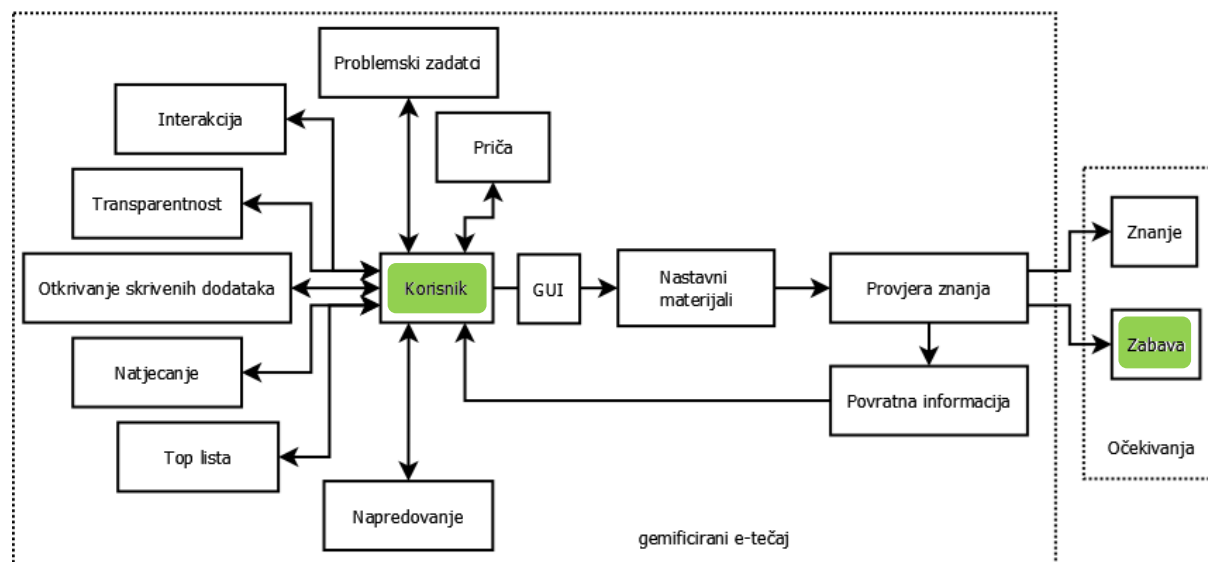
Slika 29. Pojednostavljeni model *klasičnog* e-tečaja (izvor: autor disertacije)

Na temelju pojednostavljenog modela iz slike 29. izrađen je klasičan e-tečaj kakav se može vidjeti u primjeni na većini visokoškolskih ustanova. U klasičnom e-tečaju nalaze se **nastavni materijali, provjera znanja i povratna informacija** o uspjehu koja je nakon provjere znanja vidljiva polazniku e-tečaja. Nastavni materijali su u većini slučajeva **statični i činjenično** orijentirani bez davanja uvida u širu praktičnu primjenu. Navedeno može predstavljati problem "*Generaciji Z*" o kojoj je bilo riječi u ovoj doktorskoj disertaciji u poglavlju 3.9. Na kraju nastavnog procesa od **studenta se očekuje znanje**, bez obzira na motiviranost ili osjećaj koji

² Model eRIOOS je model prema kojemu je dizajniran *eksperimentalan* e-tečaj koji je razvio autor ove disertacije. eRIOOS je skraćena od elemenata računalnih igara u online obrazovnom sustavu.

je student imao dok je koristio klasičan e-tečaj. Korist ovakvog e-tečaja je **prijenos informacija** i **dostupnost** nastavnog sadržaja u **svakom trenutku**.

Na slici 30. prikazuje se pojednostavljen model *gemificiranog* e-tečaja za *eksperimentalne* skupine ispitanika koji će biti korišten prilikom izrade konkretnih *gemificiranih* rješenja za e-tečajevu potrebu ovog doktorskog istraživanja.



Slika 30. Konceptualan eRIOOS model *gemificiranog* e-tečaja za *eksperimentalne* skupine ispitanika (izvor: autor disertacije)

Pojednostavljeni konceptualan eRIOOS model prikazan na slici 30., korisnika (studenta/igrača) okružuje *gemificiranim* elementima tj. elementima računalnih igara koji su u e-tečaj uključeni s ciljem motiviranja i zabavljanja polaznika e-tečaja. Student koristi **intuitivnije** korisničko sučelje koje je preglednije, vizualno bogatije, te jednostavnije za upravljanje i korištenje. Prije početka korištenja nastavnih materijala, studenta se upućuje u smisao e-tečaja kroz **priču** i praktične primjere čime se postiže dublji smisao i pozitivan utjecaj na intrinzičnu motivaciju. Student u vrijeme korištenja e-tečaja može pristupiti rješavanju **problemskih zadataka** vezanih za nastavnu cjelinu ili za popratne **bonus** nastavne ili nenastavne sadržaje kojima se otkrivaju **skriveni elementi** ili dijelovi sustava za e-učenje. Unutar e-tečaja osigurana je **transparentnost** po pitanju obveza na kolegiju, isto kao i po pitanju postignuća ostalih studenata. Student ima na raspolaganju **interakciju** s drugim korisnicima sustava (nastavnicima i studentima) bilo da se radi o **natjecanju** ili o međusobnoj **suradnji**. Rezultat studentskih aktivnosti vidljiv je kroz **Top liste**, ali i kroz ostale pokazatelje poput broja **bedževa**, broja **bodova** i **razine** na kojoj se student nalazi. **Napredovanje** je osigurano u vidu razina sustava i pridruživanja određenih simbola polazniku. Očekivanja od studenta su **znanje** i **viša motiviranost** za učenjem koja su osigurana većom **slobodom odabira**

pristupa nastavnim materijalima, te većom količinom vizualnih ili auditivnih **smjernica i povratnih informacija** o uspješnosti studentskih aktivnosti. Ovako dizajniran sustav za e-učenje trebao bi studentima omogućiti postizanje osjećaja **ugode, zabave i autonomnosti** nad njihovim procesom učenja, te postizanje **stanja tijeka** u kojemu je učenje najbrže.

Pojednostavljeni konceptualan eRIOOS model koji je prikazan na slici 30., prikazuje korištenje niza **elemenata računalnih igara** kojima se želi postići veća fleksibilnost i dinamičnost sustava za e-učenje. Neovisno o platformi za e-učenje, studentu bi se trebalo osigurati **suvremeno grafičko sučelje** koje podržava jednostavne animacije izbornika, pozadinsku glazbu i slične multimedijalne elemente kojima je moguće dočarati ambijent ili trenutak u priči. Navedena funkcionalnost vezana je za stvaranje jednostavnijeg i **intuitivnijeg** korisničkog ugođaja koji studentu osigurava osjećaj ugode i opuštenosti.

Svaka nastavna aktivnost trebala bi početi kao **praktičan zadatak ili problemska situacija** u kojoj se polaznika (studenta/igrača) upoznaje s mogućnostima e-tečaja, isto kao i mogućim rezultatima koji su posljedica polaznikovih aktivnosti. S obzirom na to kako se eRIOOS model usmjerava studentima visokoškolskih institucija, **priča** tj. problemska situacija trebala bi pratiti opće poznate, suvremene situacije u domeni e-tečaja. Priča bi studenta trebala staviti u ulogu *istraživača, sakupljača, pobjednika ili društvenjaka*, te ga navoditi kroz e-tečaj s ciljem aktiviranja intrinzične motivacije. Priča može biti vezana za planirane provjere znanja, te se prema rezultatima polaznika dalje dograđuje ili mijenja ovisno o postignućima grupe. Navedeno nije moguće lako postići, te se od nastavnika očekuje **usklađivanje** nastavnih sadržaja i priče sa stvarnim događajima u poslovnom svijetu. Usklađivanje nastavnih sadržaja i priče sa stvarnim događajima dovodi do ostvarivanja **višeg cilja** od jednostavnog sakupljanja bodova i učenja za rutinske provjere znanja. Navedenim se osigurava tzv. **epsko značenje** koje u *klasičnom* e-tečaju i u *tradicionalnom* obrazovanju izostaje.

Uz nastavne materijale koji su temelj sustava za e-učenje, nastoji se osigurati što je više moguće smislenih **provjera znanja** kako bi studenti u pitanje dovodili poznavanje nastavne tematike, te kako bi promišljali o određenim problemskim situacijama. Zadaci i izazovi trebali bi biti povezani s **bodovima, bedževima ili certifikatima** koji se dodjeljuju studentu ovisno o težini zadatka ili obujmu izazova. Kako se prolazi kroz sustav, tako bi zadaci i izazovi trebali biti sve teži čime se osigurava virtualan prolaz kroz nastavne cjeline. Bodovi, bedževi, certifikati ili nagrade u ostalim oblicima trebali bi biti javno vidljivi svim sudionicima, čime se osigurava **transparentnost** ocjenjivanja, isto kao i prepoznavanje znanja među polaznicima e-tečaja.

U računalnim igrama često se vide situacije kada se igrač treba suočiti s velikom preprekom u obliku glavnog neprijatelja (eng. *Boss Enemy*). U e-tečaju, takav element može biti postignut **kroz priču** u kojoj se polaznika stavlja u **stresnu situaciju** u kojoj s jedne strane postoji **vremensko ograničenje** za rješavanje problemske situacije, a s druge strane nalazi se protivnik u obliku umjetne inteligencije ili samog nastavnika. Primjer za navedeno može biti slučaj u kojem **pojedinaac** ili **tim** od nekoliko polaznika, pa čak i **cijela grupa polaznika**, dolazi u situaciju u kojoj treba "hakirati" izlaz ili ulaz u određeni prostor koji je od iznimne važnosti (prema priči koja je predstavljena na početku e-tečaja). S jedne strane su polaznici e-tečaja dok je s druge strane "protivnik" (program ili nastavnik) ovisno o razini gemificiranja sustava za e-učenje. Ovakvim primjerom lako se može postići epsko značenje.

U navedenom slučaju postiže se **sinergija i motiviranost** korisnika za pobjedom čime se na pozitivan način utječe na smjer i razvoj priče koja potpomaže obrazovni proces u sustavu za e-učenje. Sličan efekt postiže se i s **edukativnim igrama** koje su već sada dostupne u sustavima za e-učenje, ali na nešto nižoj razini apstrakcije. Bitno je osigurati višestruki pristup **interaktivnom** ponavljanju i navedenim provjerama znanja, kako bi studenti mogli **savladati** određene nastavne cjeline, isto kao i **usavršiti postojeće znanje**.

Prema Bartleu (1978.) i ostalim autorima (de Vitte i suradnici, 2015.; Gil i Cantador, 2015.) postoje sljedeći tipovi igrača: *istraživač*, *sakupljač*, *pobjednik* i *društvenjak*. Igrač rijetko pripadaju samo jednom od navedenih profila, češći je slučaj gdje igrač posjeduje osobine svih četiriju tipova igrača gdje je svaki element razvijen do neke mjere, zbog čega je i potrebno osigurati mogućnost za personalizaciju sustava za e-učenje.

Najjednostavniji način je omogućavanje korištenja **profilnih slika** nakon kojih slijede **osobne informacije i društveni statusi** čime se osigurava dijeljenje zanimljivih ili studentu važnih informacija, isto kao i dijeljenje statusa o određenim postignućima. Navedeno je vidljivo u okviru društvenih mreža koje osiguravaju dijeljenje statusa, društvenih zanimljivosti i osobnih informacija s ostalim korisnicima sustava. Sustav za e-učenje trebao bi osigurati povezivanje korisnika, kao i dijeljenje njihovih postignuća i statusa u određenom trenutku. Popratne informacije također mogu biti dostupne svim polaznicima e-tečaja ako student iste želi podijeliti putem svog **osobnog statusa** ili kroz sustave sinkrone (eng. *chat*) ili asinkrone komunikacije (eng. *forum* ili osobne obavijesti). **Sinkrona i asinkrona komunikacija** omogućuju širenje informacija između svih sudionika e-tečaja gdje se od nastavnika traži preuzimanje uloge "administratora komunikacijskih poruka". S jedne strane, potrebno je osigurati **autonomnost** po pitanju komunikacije između korisnika, dok je s druge strane nužno

usmjeravati tok podataka i napisanih informacija u smjeru **poželjnih nastavnih aktivnosti**. Uz pretpostavku kako je grupa polaznika dovoljno ozbiljna, dovoljno je postaviti **napomene** i **smjernice** za komunikaciju u određenom trenutku te pratiti tok razgovora.

Korisno je postaviti **vremenska ograničenja** za određenu nastavnu tematiku čime bi se osigurao naglasak na određenu temu. Također, poželjno je osigurati i virtualne sastanke u kojima se razgovara sa studentima o njihovim postignućima, te najaviti buduće događaje i upoznati studente s beneficijama ako je zadatak uspješno odrađen. Na taj način moguće je dodatno potaknuti polaznike za veću **zajedničku suradnju** i angažiranost, te osigurati **projektni pristup** nastavnoj cjelini ili problemskom zadatku kakav se može vidjeti u poslovnim okruženjima.

Studenti u e-tečaj dolaze s različitim predznanjem isto kao i s različitim ambicijama. **Brzina** kojom student može proći kroz nastavne materijale ne bi trebala biti ograničavajuća, međutim na nastavniku je da odluči hoće li osigurati određene **prepreke** u sustavu ili ne. Također, nije isključeno da studenti savladaju kompletnu nastavnu cjelinu prije kraja semestra, čime im se treba osigurati **bonus materijali** i **dodatna aktivnost** kojom bi se osigurala potreba za **naprednim znanjima**. Takve pojedince **nije dobro usporavati** na brzinu prosjeka grupe jer im pada interes za temom, kao i želja za daljnjim sudjelovanjem u nastavnim aktivnostima. Ako je student izvrstan, potrebno mu je omogućiti **izvannastavne** ili **bonus materijale** koji ostalim polaznicima neće biti vidljivi niti dostupni. Svi sudionici na raspolaganju imaju određene nastavne i nenastavne materijale. Nastavnik prilikom kreiranja e-tečaja određuje vremenske periode u kojima će se u sustavu dogoditi **nenajavljene promjene** po pitanju vizualnog **iznenađenja** ili po pitanju novih, do tada **skrivenih** nastavnih ili nenastavnih materijala. Navedeni elementi su elementi iznenađenja koji su planirani kako bi se polaznike sustava **razveselilo**, a pritom ih i **motiviralo** za daljnje nastavne ili nenastavne aktivnosti.

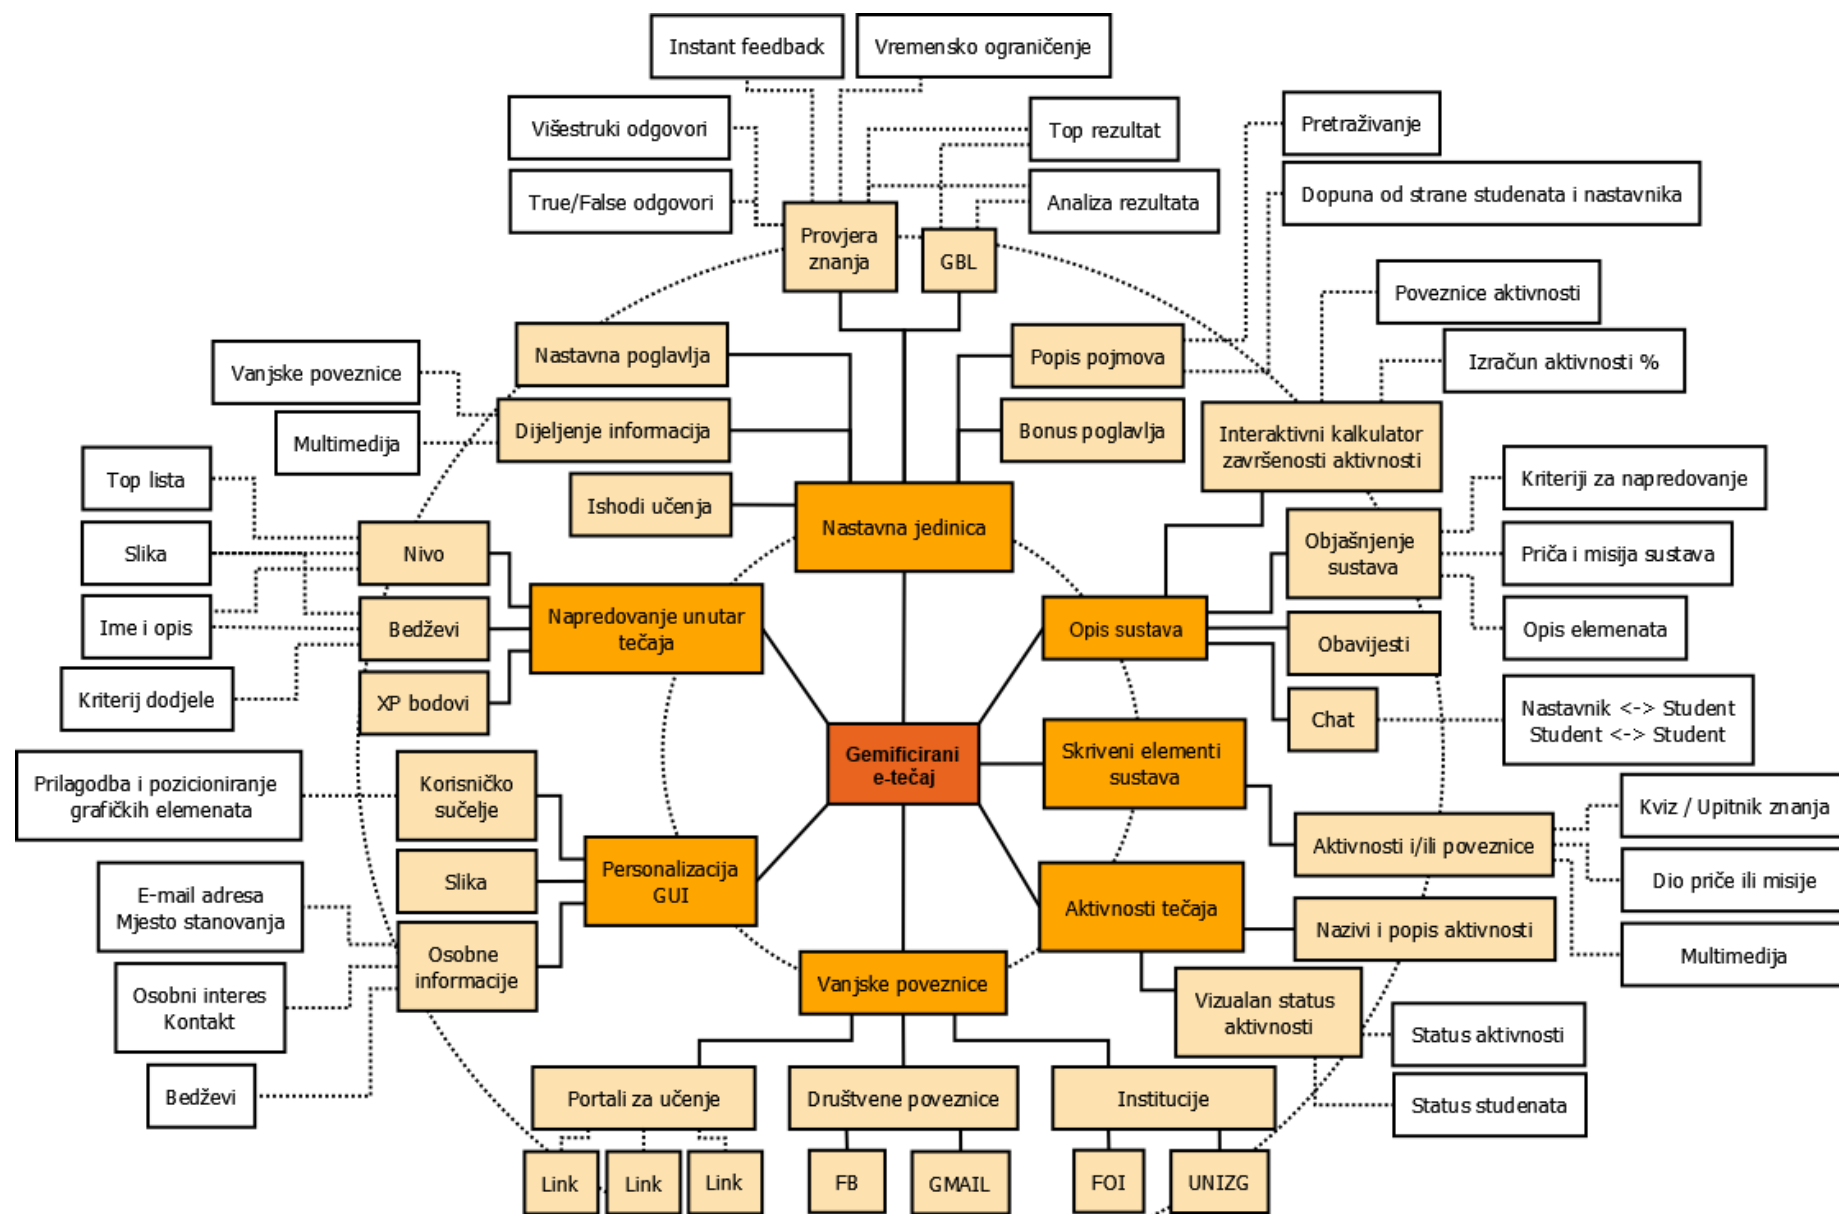
Povratna informacija o aktivnostima koje student provodi u e-tečaju, isto kao i ostale povratne informacije vezane za status napredovanja, status završenosti nastavnih obveza u e-tečaju, kao i vizualan prikaz bodova i ostalih pozitivnih postignuća koje je student tijekom vremena ispunio, važan su element *gemificiranog* sustava. Platforme za e-učenje poput Moodle-a, osiguravaju određenu razinu povratnih informacija o uspješnosti studentskih aktivnosti kojima se studenta potiče za daljnje usavršavanje i prolazak kroz nastavne i nenastavne materijale. S obzirom na to kako se u sustav za e-učenje uvode dodatni elementi iz računalnih igara, posebna pažnja treba biti usmjerena osiguravanju povratnih informacija i za te elemente ako su važne za motiviranje ili rad studenata.

eRIOOS model orijentiran je **studentu** nastavnim ili nenastavnim aktivnostima koje su studentu na raspolaganju unutar obrazovnog sustava. eRIOOS model ne donosi značajne promjene za nastavnika u vidu olakšavanja vođenja nastave ili praćenja nastavnog procesa. Čak naprotiv, **nastavnik** će u fazi planiranja i inicijalnog kreiranja e-tečaja, imati više obveza ako želi osigurati sve mogućnosti koje se modelom preporučuju.

Pojednostavljeni konceptualan eRIOOS model sa slike 29. **studentu** omogućuje:

- ❖ **intuitivnije** korisničko sučelje (eng. *Graphical User Interface, GUI*),
- ❖ postizanje dubljeg smisla kroz **priču** i praktične primjere,
- ❖ rješavanje **problemskih zadataka** vezanih za nastavne cjeline,
- ❖ rješavanje **problemskih zadataka** vezanih za popratni bonus sadržaj,
- ❖ **interakciju** s drugim korisnicima sustava (nastavnicima i studentima),
- ❖ **transparentnost** po pitanju obveza na kolegiju,
- ❖ **transparentnost** po pitanju postignuća ostalih polaznika kolegija,
- ❖ otkrivanje **skrivenih elemenata** ili dijelova sustava,
- ❖ **natjecanje** s drugim korisnicima sustava i vidljiv poredak u obliku **Top liste**,
- ❖ **napredovanje** u vidu razina sustava i pridruživanja određenih simbola polazniku,
- ❖ veću **slobodu odabira** pristupa nastavnim materijalima,
- ❖ veću količinu vizualnih ili auditivnih **smjernica** o procesu učenja,
- ❖ postizanje osjećaja **ugode, zabave i autonomnosti** nad procesom učenja,
- ❖ postizanje **stanja tijeka** u kojem je učenje najbrže.

Pojednostavljeni konceptualan model *gemificiranog* e-tečaja, prikazan na slici 30., također služi kao temelj za izradu idejnog rješenja koje je kreirano za istraživanje u okviru ovog doktorskog rada. Kreirano idejno rješenje nalazi se na slici 31., te sadrži **sedam glavnih cjelina** (*Nastavna jedinica, Opis sustava, Skriveni elementi sustava, Aktivnosti tečaja, Vanjske poveznice, Personalizacija GUI i Napredovanje unutar tečaja*). **Bijelom bojom** označeni su *gemificirani* elementi prikazani u e-tečajevima za *eksperimentalnu* skupinu ispitanika u *prvom* i *drugom glavnom istraživanju*. Svaka od sedam cjelina objašnjena je nakon slike idejnog rješenja u nastavku rada.



Slika 31. Idejno rješenje eRIOOS gemificiranog tečaja
(izvor: autor disertacije)

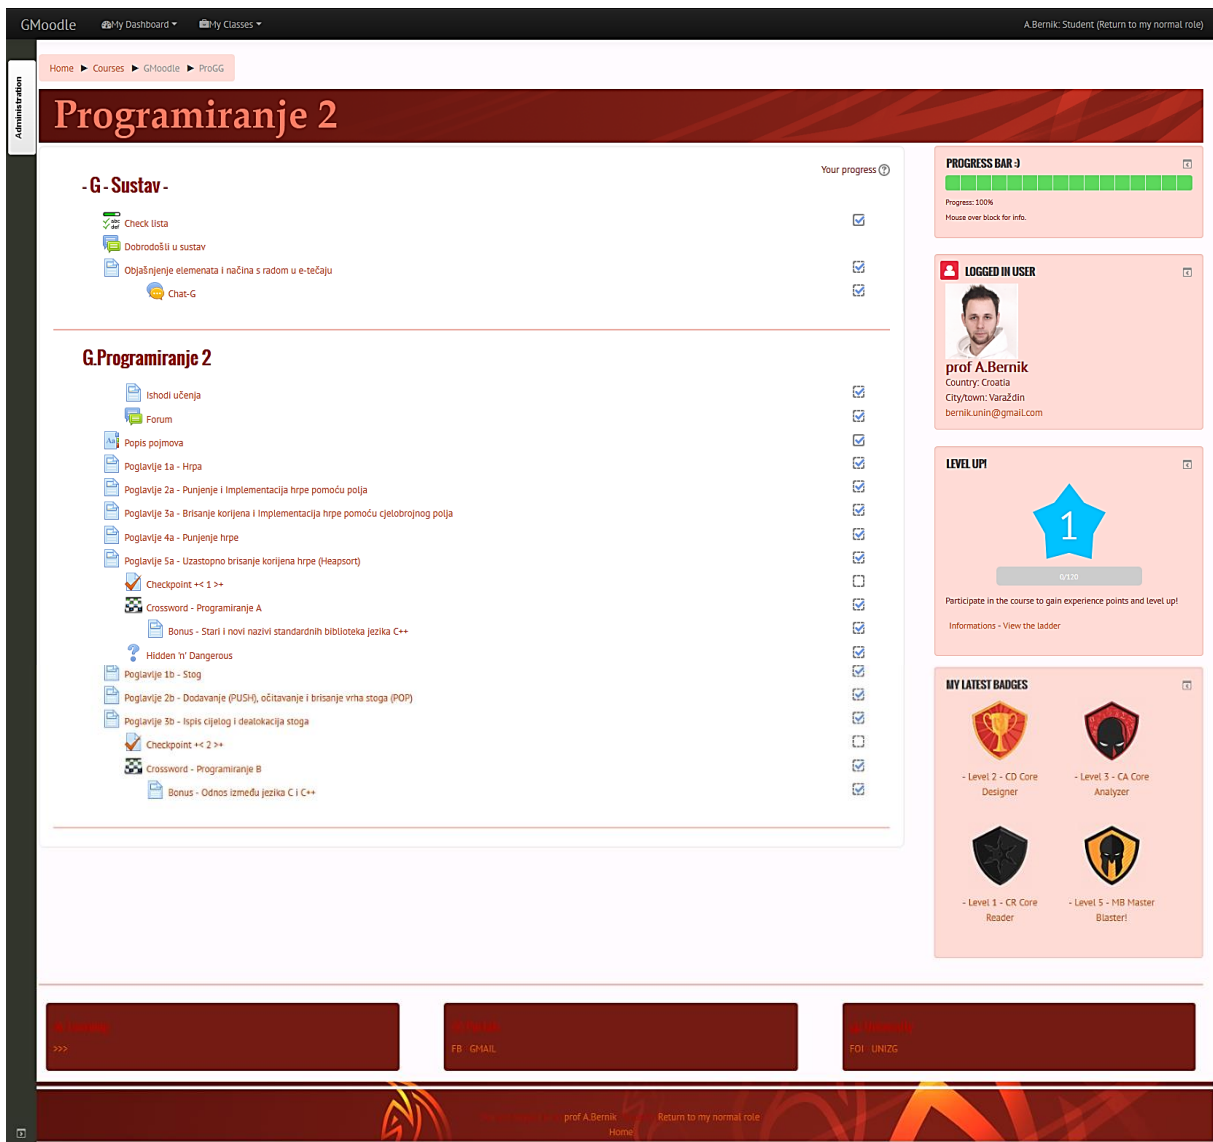
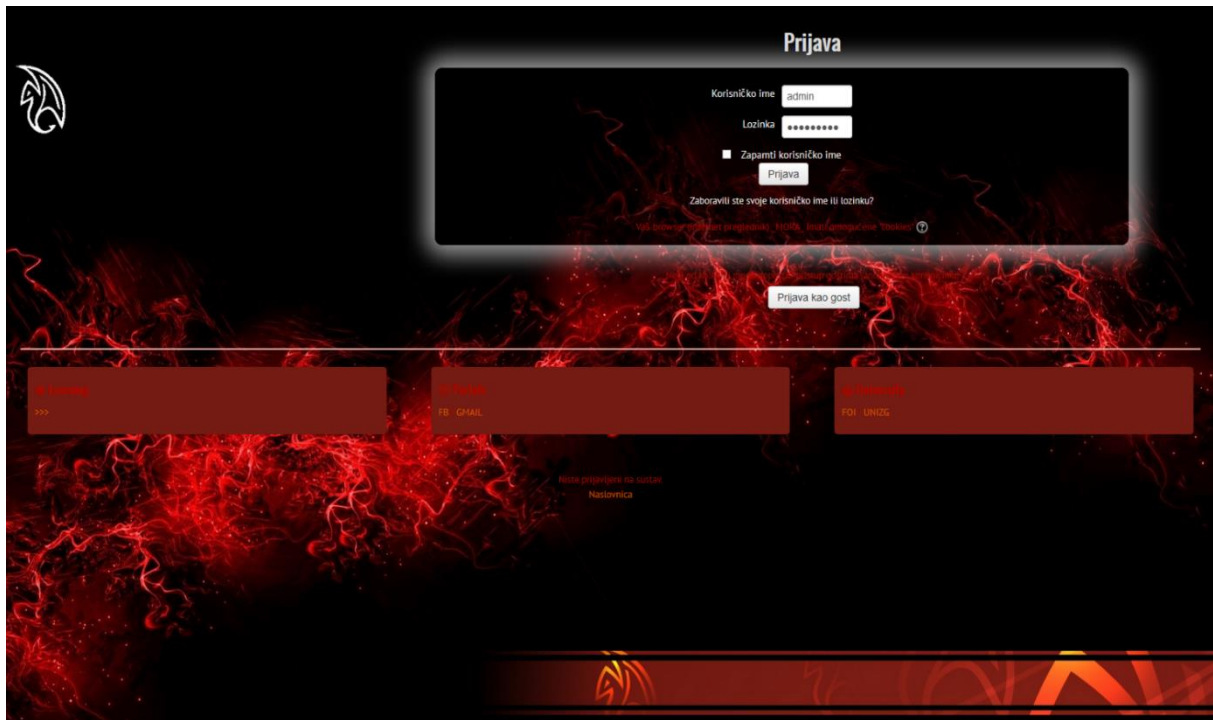
Slika 31. prikazuje primjer uključenih elemenata računalnih igara u eRIOOS model, te način na koji su elementi povezani i organizirani unutar platforme koja je namijenjena e-učenju (npr. Moodle e-tečaj).

- ❖ Prva cjelina slike 31. vodi se pod nazivom "*Nastavna jedinica*" unutar koje se nalaze ishodi učenja kolegija i pojedine nastavne jedinice. Cjelina sadrži nastavna poglavlja i bonus nastavne materijale, zadatke te izazove temeljem kojih studenti provjeravaju svoje znanje. Povratna informacija o točnosti pojedinog odgovora, vezana je uz zadatke i nastavna poglavlja, kao i uz uspješnost cjelokupne provjere znanja koja u sebi ima ugrađen mehanizam vremenskog ograničenja. Unutar nastavnih jedinica studenti mogu razmjenjivati informacije i nastavne sadržaje, ovisno o zadacima i postavkama sustava. Svi rezultati o studentskim aktivnostima su usklađeni s top listom koja je vidljiva studentima. Osim nastavnih aktivnosti, studenti mogu pretraživati ključne pojmove e-tečaja, kao i dopunjavati pojmove prema dogovoru s nastavnikom.
- ❖ Druga cjelina slike 31. nazvana je "*Opis sustava*" koja predstavlja novost s kojom se student prvi puta u ovakvom okruženju upoznaje. Unutar druge cjeline nalazi se popis svih aktivnosti i mogućnosti koje se nadgledaju i boduju od strane nastavnika. Isto tako, student ima uvid u postotak završenosti kolegija čime se daje jasan uvid u opseg e-tečaja. U posebnom dijelu nalazi se uvod u priču oko koje je e-kolegij ili e-tečaj kreiran. Po pitanju komunikacije, osiguran je asinkroni i sinkroni način razmjene informacija između svih sudionika sustava, kako između studenta, tako i između studenta i nastavnika. Obavijesti koje su vezane za e-tečaj nalaze se unutar "*Opisa sustava*", čime je osigurano kako su sve obavijesti na jednom mjestu bez uplitanja u nastavne ili nenastavne sadržaje e-tečaja.
- ❖ Treća cjelina slike 31. odnosi se na "*Skrivene elemente sustava*" temeljem kojih se ovisno o zadanom trenutku, pojavljuju dodaci u originalnom izgledu e-tečaja. Dodaci mogu biti vezani za provjeru znanja te za dopunu ili izmjenu priče ovisno o završenim aktivnostima i uspjehu studenata. Skriveni elementi mogu uključivati sve multimedijalne elemente koji mogu upotpuniti željenu atmosferu e-tečaja.
- ❖ Četvrta cjelina slike 31. prikazuje sve nastavne i nenastavne "*Aktivnosti tečaja*" koje su dostupne studentu. Osim samog popisa aktivnosti dostupan je i vizualan status aktivnosti, te status uspjeha studenata u određenom trenutku.

- ❖ Peta cjelina slike 31. odnosi se na "*Vanjske poveznice*" koje su ugrađene u e-tečaj. Vanjske poveznice osiguravaju povezanost s društvenim mrežama, isto kao i s raznim Web 2.0 alatima poput pristupa e-maila, Wikipedije ili sl. alata kojima studenti mogu na brz način upotpuniti svoje znanje ili podijeliti tražene informacije s ostalim sudionicima e-tečaja. Vanjske poveznice omogućuju brže kretanje između e-tečaja i ostalih nastavnih ili nenastavnih web portala koje studenti koriste.
- ❖ Šesta cjelina slike 31. nosi naziv "*Personalizacija GUI*". Prikazuje mogućnost unutar koje student ima nekoliko opcija po pitanju uređivanja svog profila ili osnovnog izgleda prostora u kojemu se e-učenje provodi. U profilnom prostoru, korisnik može koristiti vlastitu sliku, osnovne informacije za kontakt poput e-maila, broja telefona, mjesta stanovanja ili sl., te je osiguran prostor za osobna postignuća poput certifikata ili bedževa. Student može mijenjati izgled korisničkog sučelja u vidu proširivanja i pomicanja informacijskih blokova s lijeve na desnu stranu ovisno o potrebama.
- ❖ Sedma cjelina slike 31. vezana je za "*Napredovanje unutar tečaja*" unutar koje student ima na raspolaganju nivoe, bedževe i XP bodove (eng. *Experience*, XP). Nivoi i bedževi imaju posebna pravila prema kojima, student iste može zaraditi, a odnose se na nastavne i nenastavne aktivnosti u e-tečaju. Nivo e-tečaja direktno je vezan za algoritam kojim se dodjeljuju bodovi u e-tečaju kao što je opisano u **poglavlju 4.3**. Svaki nivo nije posebno istaknut, već samo glavni nivoi imaju posebne nazive. Svaki bedž ima svoj naziv, sliku i opis te uvjete koji se u određenom vremenskom ograničenju trebaju zadovoljiti.

Idejno rješenje sa slike 31. čini strukturu u koju je potrebno dodati nastavne materijale i sadržaje. Student je u direktnoj interakciji s osam elemenata računalnih igara i indirektno s povratnim informacijama, čime se u većoj mjeri utječe na njegov doživljaj o obrazovnom okruženju. Ako je sustav ispravno dizajniran, kod studenta se stvara osjećaj ugone koji može dovesti do **stanja tijeka** u kojemu je proces učenja optimalan. Cilj koji se želi postići bio je osiguravanje stanja tijeka u kojemu student najbrže uči uz smanjivanje osjećaja zamora i stresa koji se pojavljuje u slučaju jednolično strukturalnog e-tečaja.

Slika *gemificiranog* e-tečaja prikazan je u dva dijela na slici 32., gdje se prvi dio odnosi na početni zaslon u kojemu se od studenta traže @AAI podaci zajedno s njegovom lozinkom. Drugi dio prikazuje izgled e-tečaja koji je kreiran za kolegij "Programiranje 2". Na slici 32. vidi se struktura kolegija, grafičko rješenje, razmještaj jednog dijela aktivnosti, nastavni materijali te nenastavni elementi za *eksperimentalnu* skupinu ispitanika.



Slika 32. Grafički prikaz gemificiranog e-tečaja

5. OPIS I OBILJEŽJA ISTRAŽIVANJA

U ovom poglavlju navode se istraživanja vezana uz gemifikaciju u obrazovnim sustavima. Opisuju se istraživački ciljevi i hipoteze. Navode se instrumenti istraživačkog rada te primjeri *predtesta*, *posttesta* i *anketnog upitnika* motivacije i zadovoljstva. Poglavlje završava opisom odabranih ispitanika kroz pojedino istraživanje.

Istraživanje uvođenja elemenata računalnih igara u obrazovni sustav provedeno je na dvije visokoškolske institucije i to na Sveučilištu Sjever (UNIN), unutar odjela Multimedije oblikovanja i primjene, te na Fakultetu organizacije i informatike (FOI) u Varaždinu. Metodologija provedbe istraživanja ovog doktorskog rada izložena je u nastavku ovog poglavlja. Slijedi izrada i prikaz *gemificiranog* i *kontrolnog* obrazovnog e-tečaja, te definiranje ispitanika.

5.1. METODOLOGIJA ISTRAŽIVANJA

U daljnjem tekstu objašnjava se vremensko trajanje istraživanja, te se navode faze empirijskog tijeka istraživanja.

Vremenski okvir istraživanja

Istraživanje je provedeno unutar dvije visokoškolske institucije te uključuje redovne i izvanredne studente koji su upisali kolegij "3D modeliranje" (UNIN³), te "Programiranje 2" i "Računalom posredovana komunikacija" (FOI⁴). Sukladno obvezama koje su propisane unutar svakog kolegija, studente se **nije dodatno opterećivalo** posebnim dolascima na fakultet izvan redovne nastave. Pristup i sudjelovanje istraživanju bilo je dobrovoljno, te su unatoč tome gotovo svi studenti pristali na prisustvovanje istraživanju.

Kako bi interakcija studenata *eksperimentalne* i *kontrolne* grupe, koje mogu utjecati na procjene studenata bile što manje, planirani vremenski okvir za istraživanje bio je 20-25 radnih dana. Studentima je u navedenom razdoblju **prezentirana ideja** istraživanja. Slijedila je *predtest* provjera znanja kojom se utvrdilo predznanje studenata. Također, rezultatima *predtesta* provjerila se razlika u znanju između svih skupina ispitanika u sva tri kolegija. Za korištenje *gemificiranog* i *negemificiranog* e-tečaja osigurano je **minimalno dva tjedna** gdje su studenti mogli koristiti nastavne materijale iz pojedinog kolegija. U tjednu koji je slijedio, nakon korištenja *gemificiranog* i *negemificiranog* e-tečaja, provedena je **posttest provjera znanja** kao i *anketni upitnik* motivacije i zadovoljstva, čime je istraživanje i završilo.

³ UNIN = Sveučilište sjever / University North

⁴ FOI = Fakultet organizacije i informatike / Faculty of Organization and Informatics

U istraživanju literature, uočeno je da su drugi autori poput **Schreuders i Butterfield** (2016.), **Iosup i Epema** (2014.), te **de-Marcos i suradnika** (2014.), proveli slične eksperimente u znatno dužem trajanju, no razlika je **broj uključenih kolegija**, te **manji broj korištenih gemificiranih elemenata**, koji je u slučaju ove doktorske disertacije i višestruko veći u odnosu na te istraživače.

Faze empirijskog tijeka istraživanja

Empirijski dio istraživanja za potrebe ove doktorske disertacije, temelji se na provedbi tri odvojena istraživanja koja se u nastavku teksta navode kao *predistraživanje*, *prvo glavno istraživanje* i *drugo glavno istraživanje*. U *predistraživanju* korišten je nastavni materijal iz kolegija "3D modeliranje" te je *gemificirani* e-tečaj testiran s ciljem njegovog poboljšanja te otklanjanja tehničkih pogrešaka. Kroz dva glavna istraživanja korišteni su nastavni materijali iz kolegija "Programiranje 2" i "Računalom posredovana komunikacija" te su provjerene smjernice i zaključci *predistraživanja*, s naglaskom na postavljene ciljeve i hipoteze ovog dokorskog rada. U *predistraživanje* je uključeno 55 ispitanika. U *prvo glavno istraživanje* uključen je 201 ispitanik, te je u *drugo glavno istraživanje* uključeno ukupno 53 ispitanika. Broj ispitanika definiran je ukupnim stanjem upisanih studenata na kolegij umanjnim za pojedince koji nisu dobrovoljno sudjelovali u istraživanju. Više detalja nalazi se u **poglavlju 5.5**. Za svako istraživanje u okviru ovog dokorskog rada, zatraženo je i dobiveno dopuštenje za uključivanje studenata u eksperiment od strane nadležnih visokoškolskih tijela što je prikazano u **prilogu 1**. ove doktorske disertacije.

U **pripreмноj fazi** istraživanja provedena je analiza stručne i znanstvene literature (detaljnije opisano u poglavlju 3.), gdje se identificiraju ključni elementi mehanike, dinamike i estetike ovako složenih sustava. Istražuju se **tehnički preduvjeti** za izradu i provođenje istraživanja s obzirom na to kako se istraživanje radi na dvije odvojene visokoškolske institucije. Također, napravljena je anketa mišljenja o postojećim Moodle e-tečajevima prije provedbe *predistraživanja* i oba *glavnih istraživanja* (detaljnije opisano u poglavlju 4.1.).

U **prvoj fazi** istraživanja ponovno se prolazi kroz analizu znanstvene i stručne literature s ciljem pronalaska specifičnih smjernica za odabir Moodle elemenata koji bi bili korisni za *gemificirani* e-tečaj ovog istraživanja. Temeljem navedenog, kreiran je popis *gemificiranih* elemenata za Moodle sustav koji su prikazani u tablici 24., poglavlja 4.2.

Na temelju gemificiranih elemenata, Octalysis sustava (pogledati poglavlje 3.12.), te pronađenih smjernica iz literature, autor ove disertacije izrađuje **konceptualan gemificirani eRIOOS⁵ model** temeljem kojeg je moguće razviti cjelokupan *gemificirani* e-tečaj namijenjen za visokoškolsko obrazovanje. Na temelju eRIOOS modela u Moodle platformu uključeni su pogodni elementi računalnih igara (prema tablici 24.) pri čemu je planiran pozitivan **utjecaj** na studentovo **ponašanje** i **zainteresiranost** za nastavne i nenastavne elemente e-tečaja. U navedenom trenutku poznato je na koji način su nastavni materijali **povezani** unutar sustava, koje su potrebne **izmjene** u odnosu na postojeća Moodle rješenja, te kako povezati elemente računalnih igara u smislenu **cjelinu** s ciljem postizanja mehanike, dinamike i estetike koja je uočena u računalnim igrama **iz pripreme faze** empirijskog toka istraživanja.

Druga faza provedbe empirijskog istraživanja temelji se na fizičkoj instalaciji Moodle sustava 2.7. i povezivanja svih komponenti u jednu cjelinu. U gemificirani Moodle e-tečaj su uvedeni dodatci (eng. *plugins*) iz računalnih igara koji su prikazani u tablici 24. iz poglavlja 4.2. Na temelju prve faze i kreiranog konceptualnog modela, izrađen je **e-tečaj upotpunjen elementima računalnih igara** i to za teme "Osvjetljenje i renderiranje", "Hrpa i stog", kao i za temu "Multimedija". **Gemificirani e-tečajevi**, za sva tri istraživanja, postavljeni su na poslužitelju **Sveučilišta Sjever**. Isto vrijedi i za *negemificirani* e-tečaj koji se odnosi na *predistraživanje* ove disertacije jer se kolegij "3D modeliranje" izvodi na toj instituciji. Paralelno s navedenim razvijana je *negemificirana* verzija e-tečaja za potrebe *prvog* i *drugog glavnog istraživanja* gdje je korišten poslužitelj **Fakulteta organizacije i informatike**. Kada su oba sustava bila u potpunosti razvijena, nastupio je u proces popunjavanja nastavnih sadržaja i nastavnih materijala. Nastavni materijal prilagođen je za potrebe ovog istraživanja, te se svodi na HTML tekst popraćen slikama ili video zapisima. **Identični nastavni sadržaji i materijali** postavljaju se u oba sustava.

Treća faza u ovom istraživanju odnosi se na podjelu ispitanika u dvije odvojene skupine, *kontrolnu* i *eksperimentalnu*, te na postupak provođenja istraživanja. U tu svrhu kreiran je *pretest* kojim se provjerava studentsko predznanje. **Pretest** je sačinjen od pitanja s ponuđenim odgovorima (pitanja zatvorenog tipa), nakon kojih slijedi pitanja u kojima je potrebno objasniti određene pojmove ili riješiti određene zadatke (pitanja otvorenog tipa). Studenti za rješavanje navedenog testa imaju 30 minuta. Primjer *pretest* provjere znanja nalazi se u **poglavlju 5.4.3**.

⁵ Model **eRIOOS** je model prema kojemu je dizajniran *eksperimentalan* e-tečaj koji je razvio autor ove disertacije. **eRIOOS** je skraćenica od elemenata računalnih igara u online obrazovnom sustavu.

Analizom inicijalne pisane provjere znanja, tj. *predtesta*, za svako istraživanje posebno, načinjena je podjela ispitanika prema ostvarenim bodovima i to u dvije grupe, *kontrolnu* i *eksperimentalnu*, među kojima **nije bilo statistički značajne razlike** s obzirom na ostvareni **prosječan broj bodova**. Navedeno vrijedi za sva tri istraživanja.

Ispitanicima je objašnjen način na koji ulaze i koriste sustave. Ispitanicima je za korištenje i učenje u e-tečajevima određeno vremensko ograničenje od minimalno dva tjedna. Nastavni materijali koji su se nalazili u e-tečaju nisu bili obrađivani tehnikom **licem u lice** na predavanju, laboratorijskim niti auditornim vježbama. Studenti ih u potpunosti sami odrađuju **bez prisutnosti** nastavnika u fizičkom obliku. Nastavni materijali koji se nalaze u *gemificiranom* ili *negemificiranom* e-tečaju, **međusobno se ne razlikuju** po svom sadržaju niti po redosljedu kojim su navedeni i pozicionirani u e-tečaju pojedinog istraživanja. U tjednu koji slijedi, provodi se završna pisana provjera znanja tj. *posttest*. **Posttest** se temelji na istom principu kao i *predtest*, sadrži pitanja s ponuđenim odgovorima, nakon kojih slijede pitanja u kojima je potrebno objasniti određene pojmove ili riješiti zadatke. Studenti za rješavanje navedenog testa, imaju 30 minuta. Primjer *posttest* provjere znanja nalazi se u **poglavlju 5.4.4.** ove disertacije.

Posttest provjera znanja identična je za *eksperimentalnu* i *kontrolnu* grupu ispitanika te se odnosi isključivo na nastavne materijale e-tečaja kojeg su studenti koristili u određenom istraživanju. Po završetku provođenja *posttest* provjere znanja, studenti prolaze kroz **anketni upitnik motivacije i zadovoljstva** u kojem se kroz niz pitanja temeljenih na Likertovim skalama bilježe mišljenja o ključnim elementima e-tečaja i ostalim pokazateljima vezanim za *gemificirani* Moodle sustav. *Anketni upitnik* je dobrovoljan, nije anonimn, te ne zadire u privatnost ispitanika. Isto vrijedi i za provedene *predtest* i *posttest* provjere. Provodi se analiza završne pisane provjere znanja, isto kao i analiza *anketnog upitnika*.

Četvrta faza provedbe empirijskog istraživanja bazirana je na izračunu statističkih pokazatelja poput: standardne devijacije, t-testa, Cronbach alphe, mjere centralne tendencije, deskriptivne statistike i ostalih statističkih pokazatelja na temelju kojih je moguće donijeti pravovaljani zaključak o statističkoj razlici između ostvarenih rezultata *eksperimentalne* i *kontrolne* grupe ispitanika. Rezultati statističke obrade podataka direktno se vežu uz hipoteze koje su postavljene u ranijim fazama istraživanja, te omogućuju donošenje finalnih zaključaka o **studentskoj motivaciji, zadovoljstvu i procesu učenja**. Slijedi diseminacija informacija o cjelokupnom doktorskom radu i njegovim zaključcima te se ostavlja prostor za nova istraživanja te za redizajn *gemificiranog* Moodle e-tečaja u skladu s novim tehnološkim mogućnostima i uočenim novitetima po pitanju dodatka u nadolazećim verzijama.

5.2. ISHODI UČENJA U E-TEČAJEVIMA

5.2.1. Ishodi učenja za *predistraživanje*: "Osvjetljenje i renderiranje"

Ishodi učenja u e-tečaju "Osvjetljenje i renderiranje" mjereni su *predtestom* i *posttestom* za provjeru znanja. U *predistraživanju* provedenom unutar kolegija "3D modeliranje" *predtestom* se provjeravalo **znanje** i **razumijevanje** osnovnih pojmova kao i kognitivne kompetencije i vještine prema Bloomovoj taksonomiji (vidjeti tablicu 18.) iz područja računalne grafike. Prije provedbe *predtesta*, studenti nisu bili izloženi sadržajima koji su se pojavljivali kasnije u *eksperimentalnom* ili *klasičnom* e-tečaju. Očekivani ishodi učenja od studenata koji pristupaju empirijskom dijelu istraživanja za kolegij "3D modeliranje" bili su:

- izdvojiti (prepoznati)** elemente koji su važni za 3D računalnu grafiku.
- identificirati** zaduženja procesora i grafičke kartice.
- objasniti** rad sa 2D kamerama (nacrt, tlocrt i bokocrt) u 3D prostoru.
- objasniti** poveznicu između tekstura i materijala za sjenčanje.

Znanje i razumijevanje provjeravalo se pomoću sljedećih pitanja otvorenog tipa:

Znanje: *Koji dio računalnog hardware-a (uz monitor) je odgovoran za ispravan prikaz i rad na 3d sceni?*

Znanje: *Koji dio računalnog hardware-a je zadužen za proces renderiranja?*

Razumijevanje: *Objasnite važnost i primjenu ortogonalnih kamera (Top, Front, Side).*

Razumijevanje: *Objasnite važnost teksture i materijala za sjenčanje.*

Pitanja koja su provjeravala više razine kognitivnih vještina odnosila su se na **analizu** i **sintezu** pojmova iz područja računalne grafike, te se navode u nastavku teksta:

- izdvojiti (predložiti)** najbolju praksu u radom sa poligonima (točka, linija, ploha).
- kombinirati** različite aplikacije za računalnu grafiku.

Viša razina kognitivnih vještina provjeravala se kroz sljedeća pitanja otvorenog tipa:

Analiza: *Koji element poligona (Vertex, Edge, Face) smatrate najvažnijim prilikom modeliranja i zašto?*

Sinteza: *Objasnite mogućnosti povezivanja Maya sa srodnim programima (Cinema 4D, Blender, 3ds Max)?*

Odgovori na postavljena pitanja su analizirana, te je uočeno kako studenti *kontrolne i eksperimentalne* grupe imaju podjednako prosječno znanje što je dokazano i statističkom analizom u kojoj je vidljivo kako između navedenih grupa **ne postoji statistički značajna razlika**. Temeljem navedenog, studenti su upućeni u *gemificirani i negemificirani* e-tečaj koji je služio kao glavni izvor nastavnih materijala iz teme "Osvjetljenje i renderiranje". Studenti su e-tečaj mogli koristiti minimalno dva tjedna, nakon kojih su, u tjednu koji je slijedio, obje grupe ispitanika pristupile drugoj pisanoj provjeri znanja kojom se provjeravalo **znanje i razumijevanje** osnovnih pojmova, kao i kognitivne kompetencije i vještine prema Bloomovoj taksonomiji (vidjeti tablicu 18.), te **primjena** naučenog iz područja računalne grafike. Očekivalo se kako će nakon uspješnog prolaska kroz e-tečaj studenti moći:

- imenovati (nabrojati)** osnovne tipove svjetla u Autodesk Mayi.
- identificirati** tip virtualnog osvjetljenja s obzirom na 3d scenu.
- identificirati** tip virtualnih sjena s obzirom na 3d scenu.
- izabrati (primijeniti)** tip grafičkog pogona za iscrtavanje računalne grafike.
- objasniti** potrebu za naprednim funkcijama u procesu iscrtavanja.
- objasniti** potrebu za korištenjem naprednih vizualnih efekata.

Znanje i razumijevanje provjeravalo se kroz sljedeća **pitanja otvorenog tipa**:

Znanje: *Navedite 6 osnovnih tipova svjetla u Mayi.*

Znanje: *Renderiranje sitnih detalja koji nisu modelirani ostvaruju se pomoću kojih mapa?*

Znanje: *Kada se koristi globalna iluminacija kao izvor osvjetljenja?*

Znanje: *Kada se koriste Ray Traced sjene?*

Razumijevanje: *Koji se render engine koristi, ako se kao finalni rezultat očekuje fotorealistična slika?*

Razumijevanje: *Zašto Cache-irati photon mapu u procesu renderiranja?*

Rezultati odgovora analizirani su unutar **poglavlja 6.1.** ove disertacije.

5.2.2. Ishodi učenja za *prvo glavno istraživanje*: "Hrpa i stog"

Ishodi učenja u e-tečaju "**Hrpa i stog**" mjereni su *predtestom* i *posttestom* za provjeru znanja. *Predtestom* u *prvom glavnom istraživanju*, koje je provedeno unutar kolegija "Programiranje 2", provjeravalo se **znanje** i **razumijevanje** osnovnih pojmova kao i kognitivne kompetencije i vještine prema Bloomovoj taksonomiji (vidjeti tablicu 18.) iz područja programiranja. Prije provedbe *predtesta*, studenti nisu bili izloženi sadržajima koji su se pojavljivali kasnije u *eksperimentalnom* ili *klasičnom* e-tečaju. Očekivani ishodi učenja od studenata koji pristupaju empirijskom dijelu istraživanja za kolegij "Programiranje 2" bili su:

- objasniti** osnovne tipove podataka u programiranju.
- objasniti** osnovne funkcije u programiranju.
- definirati i opisati** osnovne pojmove u programiranju.

Znanje je provjeravano sljedećim **pitanjima otvorenog tipa**:

- Znanje: *Objasnite jednostavne i složene tipove podataka.*
Znanje: *Što je varijabla i koja su njena svojstva?*
Znanje: *Objasnite selekciju tipa "IF" i njena varijante.*
Znanje: *Objasnite pojam polja u programiranju i navedite vrste.*

Pitanja koja su provjeravala više razine kognitivnih vještina odnosila su se na **analizu** i **sintezu** pojmova iz područja programiranja te se navode u nastavku teksta:

- izraditi (napisati)** sortiranje (korak po korak) nad zadanim primjerom brojeva.

Viša razina kognitivnih vještina se provjeravala sljedećim **zadatkom otvorenog tipa**:

- Analiza: *Razradite postupak uzlaznog Bubblesort na primjeru brojeva 4, 2, 1, 3.*
Sinteza:

Kao i kod studenata koji su sudjelovali u *predistraživanju*, odgovori na postavljena pitanja su analizirani te je uočeno kako studenti *kontrolne* i *eksperimentalne* grupe imaju podjednako znanje što je dokazano i statističkom analizom u kojoj se vidi kako između navedenih grupa **nije postojala statistički značajna razlika**. Temeljem navedenog, studenti su bili upućeni u *gemificirani* i *negemificirani* e-tečaj koji je služio kao glavni izvor nastavnih materijala iz teme "Hrpa i stog". Studenti su e-tečaj mogli koristiti minimalno dva tjedna, nakon kojih su, u tjednu koji je slijedio, obje grupe ispitanika pristupile drugoj pisanoj provjeri znanja u kojoj su provjeravane više razine kognitivnih vještina (**analiza**, **sinteza**) prema Bloomovoj taksonomiji (vidjeti tablicu 18.), te **primjena** naučenog iz područja programiranja.

Očekivalo se kako će nakon uspješnog prolaska kroz e-tečaj studenti moći:

- provjeriti** ispravnost programskog koda.
- napisati (predložiti)** točno rješenje za programski zadatak.

Viša razina kognitivnih vještina provjerava se **zadacima iz posttest** provjere znanja:

1. *Ispravite pogrešku u kodu:*

```
struct cvor{
    int broj;
    telement *slijedeci;
};
cvor *vrh = NULL;
```
2. *Ispravite pogrešku u kodu:*

```
fstream dat;
dat.open ("tekst.txt",ios::in);
dat << "Prvi red teksta!\n";
dat << "Drugi red teksta!" << endl;
dat.close();
```
3. *Ispravite pogrešku u kodu:*

```
void zamjena (int &a, int &b){
    int t = a;
    a = b;
    b = t; }
void main(){
    zamjena (3,5);
    cout << x << y << endl; }
```
4. *Što će se ispisati?*

```
int *pok;
pok = new int;
*pok = 10;
cout << (bool) pok << endl;
```
5. *Što će se ispisati?*

```
void funkcija(int a, int b=5){
    cout << "a = " << a << endl;
    cout << "b = " << b << endl;
}
void main(){
    funkcija (3,4);
    funkcija (5); }
```

Rezultati odgovora analizirani su u unutar **poglavlja 6.2.** ove disertacije.

5.2.3. Ishodi učenja za *drugo glavno istraživanje*: "Multimedija"

Ishodi učenja u e-tečaju "Multimedija" mjereni su *predtestom* i *posttestom* za provjeru znanja. *Predtestom* u *drugom glavnom istraživanju* provedenom unutar kolegija "Računalom posredovana komunikacija", a koji se izvodi u okviru diplomskog studija na Fakultetu organizacije i informatike, provjeravalo se **znanje** i **razumijevanje** osnovnih pojmova kao i kognitivne kompetencije i vještine prema Bloomovoj taksonomiji (vidjeti tablicu 18.) iz područja multimedije. Prije provedbe *predtesta*, studenti nisu bili izloženi sadržajima koji su se pojavljivali kasnije u *eksperimentalnom* ili *klasičnom* e-tečaju. Očekivani ishodi učenja od studenata koji pristupaju empirijskom dijelu istraživanja za kolegij "Računalom posredovana komunikacija" bili su:

- objasniti** osnovne pojmove u informatici.
- diskutirati** osnove pojmove u informatici.
- imenovati (nabrojati)** web 2.0 alate.
- objasniti** osnovne pojmove u računalnoj grafici.
- objasniti** osnovne pojmove vezane uz Internet.

Znanje i **razumijevanje** provjeravalo se sljedećim **pitanjima otvorenog tipa**:

Razumijevanje: *Objasnite sličnost između definicija podatka i informacije.*

Razumijevanje: *Objasnite pojam znanja iz perspektive društvenih znanosti.*

Znanje: *Navedite minimalno četiri Web 2.0 alata.*

Razumijevanje: *Objasnite razliku između stalne i privremene IP adrese.*

Razumijevanje: *Objasnite razliku između vektorske i rasterske grafike.*

Razumijevanje: *Objasnite simplex i duplex način Internetske komunikacije.*

Kao i kod studenata koji su sudjelovali u *predistraživanju* i *prvom glavnom istraživanju*, analizirani su odgovori na postavljena pitanja, te je uočeno kako studenti *kontrolne* i *eksperimentalne* grupe imaju podjednako znanje što je dokazano i statističkom analizom u kojoj se vidi kako između navedenih grupa **nije postojala statistički značajna razlika**. Temeljem navedenog, studenti su upućeni u *gemificirani* i *negemificirani* e-tečaj koji je služio kao primarni izvor nastavnih materijala iz teme "Multimedija". Studenti su e-tečaj mogli koristiti dva tjedna, nakon kojih su, u tjednu koji je slijedio, obje grupe ispitanika pristupile drugoj pisanoj provjeri znanja u kojoj se provjeravalo **znanje** i **razumijevanje** osnovnih pojmova kao i kognitivne kompetencije i vještine prema Bloomovoj taksonomiji (vidjeti tablicu 18.), iz područja multimedije.

Očekivalo se kako će nakon uspješnog prolaska kroz e-tečaj studenti moći:

- objasniti** ključne elemente i pojam digitalne kompetencije.
- objasniti** značajke i pojam korisničkog sučelja.
- povezati (izdvojiti)** pojmove unutar IKT okruženja.

Razumijevanje se provjeravalo sljedećim **pitanjima otvorenog tipa**:

Razumijevanje: *Objasnite pojam i ključne elemente digitalne kompetencije.*

Razumijevanje: *Objasnite važnost i značenje dizajniranja korisničkog sučelja za multimedijske potrebe.*

Razumijevanje: *Objasnite povezanost između vizualne komunikacije i grafičkog dizajna.*

Razumijevanje: *Objasnite povezanost multimedije i suvremene komunikacije.*

Razumijevanje: *Objasnite koje su povezanosti između Web 2.0 alata i multimedije.*

Razumijevanje: *Koja su osnovna načela multimedijskog oblikovanja sadržaja za web i kompaktnu ploču (CD).*

Rezultati odgovora analizirani su unutar **poglavlja 6.3.** ove disertacije.

5.3. CILJEVI I HIPOTEZE

Osnovni cilj ovog istraživanja uvođenje je elemenata računalnih igara u sustav visokoškolskog obrazovanja i provjera učinaka *gemificiranog* sustava koji se realiziraju u nekoliko faza. Temeljem postojećih istraživanja te analizom e-učenja, računalnih igara, gemifikacije i utjecaja na motivaciju u učenju, kreirani su ciljevi koji se ostvaruju kroz ovaj istraživački rad:

- **Prvi cilj** istraživanja je ispitati potrebu za uvođenjem elemenata računalnih igara u e-učenje na visokim učilištima.
- **Drugi cilj** je istražiti motivirajuće elemente računalnih igara koji bi se mogli koristiti u području *online* poučavanja sadržaja informatičkih predmeta.
- **Treći cilj** predstavlja razvoj konceptualnog modela gemifikacije za poučavanje u *online* okruženju koji je temelj za izradu *gemificiranog* Moodle e-tečaja u području poučavanja sadržaja informatičkih predmeta.
- **Četvrti cilj** odnosi se na provjeru je li primjena motivirajućih elemenata računalnih igara omogućila ostvarenje viših razina ishoda učenja u *eksperimentalnoj* skupini ispitanika. Konceptualni model usmjeren je unapređenju i primjeni elemenata raćunalnih igara u online obrazovnom sustavu (eRIOOS).

S ciljem preciznijeg definiranja smjera istraživanja, postavljene su sljedeće hipoteze:

- **H1.** E-tečaj dizajniran uz primjenu elemenata računalnih igara **pozitivno utječe** na **zainteresiranost** polaznika tog tečaja u odnosu na tečaj istog obrazovnog sadržaja, ali bez prisutnosti elemenata računalnih igara.
- **H2.** E-tečaj dizajniran uz primjenu elemenata računalnih igara omogućuje postizanje **boljih rezultata** polaznika u odnosu na tradicionalne pristupe e-učenju, imajući u vidu razinu **stečenog znanja** iz određenog nastavnog sadržaja.

Osim hipoteze **H1**, definirana je i sljedeća podhipoteza H1.1. koja glasi:

- **H1.1.** Elementi računalnih igara, koji su uključeni u *eksperimentalni* e-tečaj, **pozitivno utječu** na **veće korištenje nastavnih materijala, u usporedbi s klasičnim e-tečajem koji** sadrži identične nastavne materijale, bez prisutnosti elemenata računalnih igara.

Osim hipoteze **H2**, definirane su i sljedeće podhipoteze **H2.1**, **H2.2**, **H2.3**, **H2.4** i **H2.5**. koje se redom navode u nastavku ovog rada:

- **H2.1.** *Eksperimentalna* grupa ispitanika, koja je u *predtest* provjeri znanja ostvarila **minimalno 50%** bodova, postići će **statistički značajnije** rezultate u odnosu na *kontrolnu* grupu ispitanika, koja je u *predtest* provjeri znanja ostvarila **minimalno 50%** bodova, s obzirom na ostvarene bodove u *posttest* provjeri znanja.
- **H2.2.** Bez obzira na spol ispitanika, **50% najbolje** rangiranih studenata *eksperimentalne* grupe ispitanika, *prvog glavnog istraživanja*, ostvarit će statistički značajniji rezultat u odnosu na **50% najbolje** rangiranih studenata *kontrolne* grupe ispitanika.
- **H2.3.** Bez obzira na spol ispitanika, **50% najlošije** rangiranih studenata *eksperimentalne* grupe ispitanika, *prvog glavnog istraživanja*, ostvarit će statistički značajniji rezultat u odnosu na **50% najlošije** rangiranih studenata *kontrolne* grupe ispitanika.
- **H2.4.** Bez obzira na predznanje ispitanika, studenti **muškog spola** *eksperimentalne* grupe u *prvom glavnom istraživanju* ostvarit će statistički značajniji rezultat u odnosu na studente **muškog spola** *kontrolne* grupe ispitanika.
- **H2.5.** Bez obzira na predznanje ispitanika, studenti **ženskog spola** *eksperimentalne* grupe u *prvom glavnom istraživanju* ostvarit će statistički značajniji rezultat u odnosu na studente **ženskog spola** *kontrolne* grupe ispitanika

Za provjeru hipoteza **H1** i **H2**, te podhipoteza **H1.1**, **H2.1**, **H2.2**, **H2.3**, **H2.4** i **H2.5** korištene su opće znanstvene metode poput opservacije, deskripcije, metode komparacije, metode sinteze i analize sadržaja, a posebice i metode statističke obrade empirijski prikupljenih podataka (t-test). Važno je naglasiti kako se podhipoteze **H2.2**, **H2.3**, **H2.4** i **H2.5** odnose samo na rezultate *prvog glavnog istraživanja* zbog **nedovoljno velikog uzorka** ispitanika koji su sudjelovali u istraživačkim aktivnostima provedenim unutar *predistraživanja* i *drugog glavnog istraživanja* ovog doktorskog rada.

- Metode** koje su korištene za dokazivanje hipoteze H1, te podhipoteze H1.1 su metoda opservacije, deskripcije, komparacije, te metoda sinteze i analize sadržaja.
- Metode** koje su korištene za dokazivanje hipoteze H2, te podhipoteze H2.1, H2.2, H2.3, H2.4 i H2.5 su metoda komparacije i statističke obrade podataka (t-test).

5.4. INSTRUMENTARIJ

Za potrebe ovog istraživačkog rada korištene su provjere znanja i *anketni upitnik* motivacije i zadovoljstva s ukupno 16 skala i 210 čestica. Prvi dio *anketnog upitnika* broji 19 čestica koje se odnose na osobne podatke ispitanika. Drugi dio broji ukupno 150 čestica koje se odnose na povratne informacije o e-tečaju, dok treći sadrži 41 česticu koja se odnosi na utjecaj motivacijskih elemenata iz računalnih igara na učenje ispitanika. Provjera znanja dijeli se na test za provjeru studentovog **predznanja** (u daljnjem tekstu *predtest*) i na test za provjeru **znanja** nakon provedenog eksperimenta (u daljnjem tekstu *posttest*). Provjere znanja sastoje se od pitanja **zatvorenog tipa** gdje su odgovori na pitanja unaprijed ponuđeni, te od pitanja **otvorenog tipa** gdje student treba **objasniti** pojam, napraviti **usporedbu** ili u slučaju *prvog glavnog istraživanja*, gdje je potrebno **otkriti pogrešku** i/ili **riješiti problemski zadatak**. Primjeri *predtest* i *posttest* provjere znanja nalaze se u tablicama 31. i 32.

Anketni upitnik motivacije i zadovoljstva korišteni su za prikupljanje **mišljenja studenata** o *eksperimentalnom* sustavu, **motivacijskim elementima računalnih igara**, sustavima **poticanja, nagrađivanja** i dr. Kreirani su temeljem teorijskog dijela istraživanja i upitnika drugih autora. Jedan dio mjernih skala u upitnicima u potpunosti je kreiran od strane autora ove disertacije, dok je ostatak prilagođen temeljem mjernih skala koje su kreirali drugi autori. U svim fazama istraživanja studenti su u provjerama znanja, te u *anketnom upitniku* motivacije i zadovoljstva koristili ime, prezime, tip studiranja i broj indeksa. Provjere znanja i *anketni upitnik* ne zadiru u privatnost ispitanika, a prisustvovanje je u potpunosti dobrovoljno. Korištenjem osobnih identifikacijskih oznaka postiže se dodatna ozbiljnost u pristupanju popunjavanja odgovora, te se ujedno i osigurava lakša analiza studentskih odgovora.

U tablici 27. navodi se lista autora te nazivi istraživanih skala koje su korištene u svrhu izrade instrumenta za potrebu ove doktorske disertacije. Popis svih skala i čestica koje su korištene u istraživačkim aktivnostima ove disertacije nalazi se u **prilogu 3. i 4.** ove doktorske disertacije.

Tablica 27. Autori i teme istraživanih skala koje su korištene za kreiranje ankete, odnosno novih mjernih skala

Rbr	Autor i godina	Tema istraživane skale
1.	C. Gardner i suradnici (2004.)	Internetske tehnologije i njihova prihvaćenost
2.	Ø. Sørebo i suradnici (2009.)	Utjecaj teorije samo određivanja na motivaciju prilikom korištenja alata za e-učenje
3.	F. Ling Fu i suradnici (2009.)	Mjerenje užitka prilikom igranja u e-tečaju
4.	S. Liu i suradnici (2009.)	Utjecaj kompleksnosti medija i tijeka na prihvaćenost tehnologije za e-učenje
5.	M.J. Parnell (2009.)	Procjena iskustva korištenjem računalnih igara
6.	E.H. Calvillo-Gámez i suradnici (2010.)	Procjena i evaluacija elemenata igraćeg iskustva
7.	M. Paechter i suradnici (2010.)	Očekivana postignuća i zadovoljstvo e-tečaja
8.	H. Shroff i suradnici (2011.)	Prihvaćenost tehnoloških rješenja e-sustava
9.	I. Kovačević i suradnici (2013.)	Motivacijski činitelji za obrazovne sadržaje
10.	Y. Huang i suradnici (2013.)	Prihvatljivost korisničkog sučelja
11.	I. Esteban-Millat i suradnici (2014.)	Zanesenost studenata u <i>online</i> sustavu obrazovanja
12.	J. Hamari i suradnici (2014.)	Mjerenje tijeka u gemifikaciji
13.	F.A.M. Pereira i suradnici (2015.)	Zadovoljstvo ponavljajućeg korištenja servisa za e-učenje
14.	R. Ryan i suradnici (2015.)	Činitelji intrinzične motivacije

Kreirane ili prilagođene mjerne skale navode se u nastavku teksta:

Naziv mjerne skale:

Reference prema kojima su čestice kreirane:

1. Osobni podaci	⇒	Autor disertacije samostalno
2. Zadovoljstvo korištenja e-tečaja	⇒	Parnell (2009.)
3. Pregled nad tečajem / navigacija	⇒	Autor disertacije i Parnell (2009.)
4. Povratne informacije u e-tečaju	⇒	Fu (2009.); Kovačević (2013.)
5. Zaokupljenost / uživljanje	⇒	Parnell (2009.); Fu (2009.)
6. Priprema / uputa za rad s e-tečajem	⇒	Autor disertacije; Parnell (2009.); Fu (2009.)
7. Primjerena težina e-tečaja	⇒	Autor disertacije; Parnell (2009.); Fu (2009.)
8. Motivacijski elementi e-tečaja	⇒	Parnell (2009.); Paechter (2010.); Esteban-Millat (2014.)
9. Agregacija elemenata za motivacijske poticaje	⇒	Autor disertacije samostalno
10. Interakcija unutar e-tečaja	⇒	Fu (2009.); Paechter (2010.); Parnell (2009.)
11. Postignuće učenja	⇒	Fu (2009.); Paechter (2010.); Esteban-Millat (2014.)
12. Individualni proces učenja	⇒	Paechter (2010.)
13. Doživljaj e-tečaja	⇒	Calvillo-Gámez (2010.)
14. Evaluacija e-tečaja	⇒	Ryan (2015.)
15. Općeniti motivacijski elementi	⇒	Autor disertacije samostalno
16. Evaluacija elemenata računalnih igara	⇒	Autor disertacije samostalno

U sva tri istraživanja korištene su ranije navedene *predtest* i *posttest* provjere znanja, te *anketni upitnik motivacije i zadovoljstva*. Studenti su za svoje vrijeme i aktivnost nagrađeni dodatnim bodovima u okviru kolegija na kojima se provodilo istraživanje.

5.4.1. Postupak izrade skala za mjerenje pojedinih konstrukata u anketnom upitniku

Skale u anketnom upitniku odabrane su, dorađivane i (samo)kreirane prema sljedećim općim pravilima i procedurama:

A) Zadržavanje istovjetnih skala kao što su navedene u literaturi. Skala navedena u literaturi provjerena je u odnosu na definiciju konstrukta kojeg bi trebala mjeriti imajući u vidu tzv. površinsku valjanost (engl. *face validity*) i sadržajnu valjanost (engl. *content validity*), kao i podatke iz literature o njenoj unutarnjoj konzistenciji te korelaciji s drugim konstruktima. Površinsku valjanost već gotovih skala drugih autora provjerio je prvo doktorski kandidat, a potom njegov mentor koji ima iskustvo iz područja psihološkog mjerenja te konstrukcije mjernih skala, upitnika i anketa. Svaka čestica skale analizirana je u odnosu na semantičko značenje konstrukta kojeg bi trebala mjeriti, imajući pritom u vidu i psihološko doživljavanje ispitanika te izbjegavanje istih riječi u različitim česticama skale na način da se takve riječi prema potrebi zamjenjuju sinonimima.

B) Dorađivanje skala navedenih u literaturi. U ovom slučaju analizirane su postojeće skale za mjerenje pojedinih konstrukata te je započeta njihova dorada ako je: (a) utvrđeno da neke čestice prema površinskoj ili sadržajnoj valjanosti (engl. *content validity*) ne reprezentiraju konstrukt na dovoljno dobar način, (b) izvorna skala ima manje od 4 čestice, (c) izvorna skala ima u različitim česticama previše ponavljanja istih ili sličnih riječi, (d) kombinacije (a), (b) ili (c). U ovom slučaju načinjeno je sljedeće:

- u slučaju nedovoljnog broja čestica korištene su pogodne čestice iz drugih skala ili su prepravljane tako da (a) dopunjavaju ili zaokružuju opis širine konstrukta ili (b) ne ponavljaju sadržaje drugih zadržanih čestica; također su novokreirane dodatne čestice prema definiciji konstrukta na način da se ispunjavaju prethodni kriteriji (a) i (b);
- prilikom analize novih i starih čestica u dorađenoj skali korišteni su isti principi kao i kod A. (*Površinsku sadržajnu valjanost dorađenih skala provjerio je prvo doktorski kandidat, a potom njegov mentor koji ima iskustvo iz područja psihološkog mjerenja te konstrukcije mjernih skala, upitnika i anketa. Svaka čestica skale analizirana je u odnosu na semantičko značenje konstrukta kojeg bi trebala mjeriti, imajući pritom u vidu i psihološko doživljavanje ispitanika te izbjegavanje istih riječi u različitim česticama skale tako da se takve riječi prema potrebi zamjenjuju sinonimima.*)

C) Novokreirane skale. Prema opisima/definicijama konstrukata u literaturi kreirane su nove čestice za skale koje nisu nađene u literaturi. Pritom se nastojalo postići da takve novokreirane čestice (a) što bolje opisuju konstrukt i (b) svojim značenjem budu što više semantički udaljene od opisa drugih konstrukata za čije mjerenje su također bile predviđene ili preuzete skale u anketnom upitniku. Dakle, za sve novokreirane skale učinjeno je sljedeće:

- oblikovanje čestica tako da su semantički što sličnije nekom elementu konstrukta prema literaturi;
- nastojanje da novokreirane čestice u odgovarajućoj skali po svojem značenju budu što više semantički udaljene od opisa ili definicije konstrukta kojeg mjeri neka druga skala;
- nastojanje da čestice budu jasne i jednoznačne te da predviđena psihološka reakcija ispitanika na njih odgovara opisu konstrukta;
- nastojanje da različite čestice nemaju istovjetne riječi ili preveliku semantičku sličnost kako bi područje mjerenja konstrukta bilo dovoljno široko;
- na kraju je prvo doktorski kandidat, a potom i mentor, izvršio provjeru površinske i sadržajne valjanosti novokreirane skale (isto kao od A. i B.).

Napomena: Sve skale detaljno su evaluirane metodom izračuna Cronbachovog alpha koeficijenta te su iz skala nakon predistraživanja isključene čestice s niskom korelacijom s korigiranom bruto vrijednošću skale. Kod prvog i drugog glavnog istraživanja čestice u anketi s niskom korelacijom s bruto rezultatom u skali za mjerenje određenog konstrukta isključene su iz daljnje statističke obrade jer se "psihološki" nisu uklapale u način "zaokruženog" doživljavanja konstrukta od strane ispitanika.

Načinjena je **faktorska analiza** metodom glavnih komponenata za fiksnih 11 faktora i sa *varimax* rotacijom za sljedećih 11 skala *anketnog upitnika* te za podatke iz **prvog glavnog istraživanja** (N=182). Rezultati su pokazali da se rotirani faktori 100% poklapaju s mjernim skalama i svi osim prvog (Razni motivacijski poticaji) ispunjavaju kriterij da je projekcija bruto vrijednosti skale / konstrukta na odgovarajući faktor za **0.30 jedinica** veći od prve sljedeće korelacije neke druge skale na isti faktor, što je indirektni dokaz da je predmet mjerenja većine skala jedinstven, tj. da među njihovim predmetima mjerenja nema prevelikih preklapanja. Tablični prikaz **faktorske analize anketnog upitnika** za podatke iz **prvog glavnog istraživanja** (N=182) pogledajte u **prilogu 4.** ove doktorske disertacije.

5.4.2. Primjer dijela anketnog upitnika motivacije i zadovoljstva

Primjer jednog dijela kreiranog *anketnog upitnika* nalazi se u tablicama 28. do 30.

Tablica 28. Primjer skale iz *anketnog upitnika "Zadovoljstvo"* (skala 2/15)

Uživao/la sam u korištenju e-tečaja.	1 2 3 4 5
Estetske karakteristike e-tečaja nisu bile impresivne.	1 2 3 4 5
Htio sam istražiti sadržaje i mogućnosti e-tečaja.	1 2 3 4 5
E-tečaj me nije uspio motivirati da ga nastavim koristiti.	1 2 3 4 5
E-tečaj mi se učinio zabavnim.	1 2 3 4 5
Rad se e-tečajem me je obradovao.	1 2 3 4 5
Bilo mi je dosadno koristiti e-tečaj.	1 2 3 4 5
Izgled e-tečaja meni je bio zanimljiv.	1 2 3 4 5

* čestice su preuzete i prilagođene prema **Parnell** (2009.)

Tablica 29. Primjer skale iz *anketnog upitnika "Zaokupljenost /uživljavanje"* (skala 5/15)

Uspio/uspjela sam se jako uživjeti u e-tečaj.	1 2 3 4 5
Nisam gubio(la) osjećaj za vrijeme tijekom rada sa e-tečajem.	1 2 3 4 5
E-tečaj je jako privlačio moju pozornost.	1 2 3 4 5
Bio/bila sam usredotočen(a) na zadatke u e-tečaju.	1 2 3 4 5
Dok sam koristio(la) e-tečaj, razmišljao(la) sam o stvarima koje <u>nisu</u> povezane sa e-tečajem.	1 2 3 4 5
Mogao(la) sam se poistovjetiti s drugim korisnicima e-tečaja.	1 2 3 4 5
Tijekom rada s e-tečajem <u>nije</u> bilo moguće skrenuti moju pozornost sa zadataka u tečaju.	1 2 3 4 5
Spontano sam se fokusirao/fokusirala na e-tečaj.	1 2 3 4 5

* čestice su preuzete i prilagođene prema **Parnell** (2009.), **Fu** i suradnici (2009.)

Tablica 30. Primjer skale iz *anketnog upitnika "Postignuće učenja"* (skala 10/15)

Korištenje e-tečaja je povećalo moje znanje.	1 2 3 4 5
Savladao(la) sam osnovne ideje vezane uz traženo znanje u sklopu e-tečaja.	1 2 3 4 5
Pokušao(la) sam vlastito znanje što više primijeniti u e-tečaju.	1 2 3 4 5
E-tečaj je motivirao korisnike za povezivanje naučenog znanja.	1 2 3 4 5
Htio/htjela sam što više znati više o predmetu/znanju koje se poučavalo e-tečajem.	1 2 3 4 5
E-tečaj je dobro omogućavao stjecanje znanja i vještina o promatranoj temi.	1 2 3 4 5
E-tečaj je omogućavao stjecanje vještina za praktičnu primjenu znanja.	1 2 3 4 5
E-tečaj je omogućavao stjecanje vještina za komunikaciju i suradnju.	1 2 3 4 5

* čestice su preuzete i prilagođene prema **Fu** (2009.), **Paechter** (2010.), **Esteban-Millat** (2014.)

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Anketni upitnik motivacije i zadovoljstva za sva tri istraživanja navodi se u prilogima 3. i 4.

5.4.3. *Predtest* provjera znanja

Predtest je test predznanja koji se koristi u svrhu upoznavanja ispitanika i ispitivanja početnih statističkih značajnosti razlika. Na temelju ostvarenih bodova, kreirane su grupe ispitanika čime se osigurava ravnopravan odnos i zadovoljavaju se početni uvjeti istraživanja.

- *Predtest* u *predistraživanju* sadrži 32 pitanja (26 pitanja s 5 ponuđenih odgovora i 6 pitanja s prostorom za vlastoručno upisivanje odgovora). Pitanja su obuhvaćala općenite pojmove iz područja 3D računalne grafike, poput pitanja o **poligonima, teksturama, alatima za manipulaciju oblika** i sl. Primjer pitanja iz *predtesta* kolegija "3D modeliranje" nalazi se u tablici 31. i u prilogu ovog rada (u **prilogu 2., slika E**).
- *Predtest* u *prvom glavnom istraživanju* sadrži jedno pitanje po cjelini manje, te tako broji ukupno 30 pitanja (25 pitanja s 4 ponuđena odgovora i 5 pitanja s prostorom za vlastoručno upisivanje odgovora). Pitanja su obuhvaćala općenite pojmove iz područja programiranja, poput pitanja o **naredbama programa C++, varijablama, logičkim operatorima** i sl. Primjer pitanja iz *predtesta* kolegija "Programiranje 2" nalazi se dijelom u tablici 31. i u prilogu ovog rada (navedeno je u **prilogu 2., slika G**).
- *Predtest* u *drugom glavnom istraživanju* sadrži 32 pitanja (26 pitanja s 5 ponuđenih odgovora i 6 pitanja s prostorom za vlastoručno upisivanje odgovora). Pitanja su obuhvaćala općenite pojmove iz područja multimedije, poput pitanja o **osnovnim elementima multimedije, hipertekstu, video zapisu, bojama, formatima** i sl. Primjer pitanja iz *predtesta* kolegija "Računalom posredovana komunikacija" nalazi se dijelom u tablici 31. i u prilogu ovog rada (navedeno je u **prilogu 2., slika I**).

Tablica 31. Primjer ispitnih pitanja *predtesta* (**3D, PRO, RPK**)

Primjeri pitanja zatvorenog tipa	Primjeri pitanja otvorenog tipa
Što predstavlja pojam <i>Depth of Field</i>? <input type="checkbox"/> zamućenost svjetla. <input type="checkbox"/> zamućenost kretnje. <input type="checkbox"/> zamućenost pogleda. <input type="checkbox"/> zamućenost sjene. <input type="checkbox"/> ništa od navedenog.	Objasnite važnost i primjenu ortogonalnih kamera (Top, Front, Side)? (... prostor za odgovor ispitanika)
Što se ispisuje? <code>int a=0x12; cout << a;</code> <input type="checkbox"/> 12 <input type="checkbox"/> 18 <input type="checkbox"/> 0x12 <input type="checkbox"/> 16	Razradite postupak uzlaznog Bubblesort na primjeru brojeva 4, 2, 1, 3. (... prostor za odgovor ispitanika)
Dubina boje (Color depth) se definira kao? <input type="checkbox"/> Broj piksela kojim se boja opisuje. <input type="checkbox"/> Broj vektora kojim se boja opisuje. <input type="checkbox"/> Broj rastera kojim se boja opisuje. <input type="checkbox"/> Broj bitova kojim se boja opisuje. <input type="checkbox"/> Ništa od navedenog.	Objasnite <i>simplex</i> i <i>duplex</i> način Internetske komunikacije. (... prostor za odgovor ispitanika)

3D = "3D modeliranje", **PRO** = "Programiranje 2", **RPK** = "Računalom posredovana komunikacija"

5.4.4. Posttest provjera znanja

Posttest je test stečenog znanja koji se koristi u svrhu provjere znanja nakon provedenog eksperimenta te služi za utvrđivanje statistički značajnih razlika između uključenih ispitanika.

- *Posttest* u **predistraživanju** sadrži ukupno 32 pitanja. Struktura pitanja ista je kao i u ranije provedenom *predtestu*. Pitanja su obuhvaćala specifične pojmove iz područja 3D računalnog osvjetljenja i renderiranja, poput pitanja o **ambijentalnom osvjetljenju, mapama fotona, zamućenosti pogleda, praćenju zraka svjetlosti** i sl. Primjer pitanja iz *posttesta* kolegija "3D modeliranje" nalazi se u tablici 32. i u prilogu rada (**Slika F**).
- *Posttest* u **prvom glavnom istraživanju** sadrži 30 pitanja. Struktura pitanja ista je kao i u ranije provedenom *predtestu*. Pitanja su obuhvaćala specifične pojmove iz područja programiranja, poput pitanja o **izračunavanju podređenog čvora hrpe, operacijama nad stogom, NULL pokazivaču** i sl. Primjer pitanja iz *posttesta* kolegija "Programiranje 2" nalazi se u tablici 32. i u prilogu rada (**prilog 2., Slika H**).
- *Posttest* u **drugom glavnom istraživanju** sadrži 31 pitanja (25 pitanja s 5 ponuđenih odgovora i 6 pitanja s prostorom za vlastoručno upisivanje odgovora). Struktura pitanja ista je kao i u ranije provedenom *predtestu*. Pitanja su obuhvaćala specifične pojmove iz područja multimedije, poput pitanja o **frekvencijskom uzorkovanju, MIDI i WAV datotekama, komprimiranju podataka, formatima animacije** i sl. Primjer pitanja iz *posttesta* kolegija "Računalom posredovana komunikacija" nalazi se dijelom u tablici 32. i u prilogu ove doktorske disertacije (navedeno je u **prilogu 2., slika J**).

Tablica 32. Primjer ispitnih pitanja *posttesta* (3D, PRO, RPK)

Primjeri pitanja zatvorenog tipa	Primjeri pitanja otvorenog tipa
<p>Detail Map sjene su:</p> <p><input type="checkbox"/> Podvrsta Raytrace Map sjena.</p> <p><input type="checkbox"/> Podvrsta Ambient Map sjena.</p> <p><input type="checkbox"/> Podvrsta Depth Map sjena.</p> <p><input type="checkbox"/> Podvrsta Sun Map sjena.</p> <p><input type="checkbox"/> Ništa od navedenog.</p>	<p>Kada se koristi globalna iluminacija kao izvor osvjetljenja?</p> <p>(... prostor za odgovor ispitanika)</p>
<p>Indeks podređenog čvora za čvor i u hrpi izračunava se po formuli:</p> <p><input type="checkbox"/> podređeni = $i * 2 + 1$</p> <p><input type="checkbox"/> podređeni = $i * 2 - 1$</p> <p><input type="checkbox"/> podređeni = $(i - 1) / 2$</p> <p><input type="checkbox"/> podređeni = $(i - 1) * 2$</p>	<p>Što će se ispisati?</p> <pre>int *pok; pok = new int; *pok = 10; cout << (bool) pok << endl;</pre> <p>(... prostor za odgovor ispitanika)</p>
<p>Frekvencijsko uzorkovanje kod zvuka je broj:</p> <p><input type="checkbox"/> Tonova u sekundi.</p> <p><input type="checkbox"/> Ponavljanja u sekundi.</p> <p><input type="checkbox"/> Instrukcija u sekundi.</p> <p><input type="checkbox"/> Uzoraka u sekundi.</p> <p><input type="checkbox"/> Ništa od navedenog.</p>	<p>Objasnite pojam i ključne elemente digitalne kompetencije.</p> <p>(... prostor za odgovor ispitanika)</p>

3D = "3D modeliranje", **PRO** = "Programiranje 2", **RPK** = "Računalom posredovana komunikacija"

5.5. ISPITANICI

Istraživački rad u okviru *predistraživanja* proveden je na **Sveučilištu Sjever (UNIN)** na odjelu "Multimedija oblikovanje i primjena" u Varaždinu u ljetnom semestru akademske godine 2014./2015. Sudionici ovog istraživanja bili su studenti druge godine koji su upisali izborni kolegij pod nazivom "**3D modeliranje**", skraćenog naziva "**3D**". U ovom istraživanju dobrovoljno je sudjelovalo 55 ispitanika koji su pohađali e-tečaj pod nazivom "Osvjetljenje i renderiranje". Ispitanici su bili podijeljeni u četiri skupine po 15 studenata.

Istraživanje u okviru *prvog glavnog istraživanja* provodilo se na **Fakultetu organizacije i informatike (FOI)** u Varaždinu na dva kolegija studija informacijskih znanosti u zimskom semestru akademske godine 2015./2016. Prvi kolegij je "**Programiranje 2**", skraćenog naziva "**PRO**". U ovom istraživanju dobrovoljno je sudjelovao 201 ispitanik koji su pohađali e-tečaj "Hrpa i stog". Ispitanici su bili odvojeni u 14 skupina po 15 studenata. Drugi kolegij je "**Računalom posredovana komunikacija**", skraćenog naziva "**RPK**" koji se koristio u *drugom glavnom istraživanju*. U istraživanju je dobrovoljno sudjelovalo 53 ispitanika koji su pohađali e-tečaj "Multimedija". Ispitanici su bili odvojeni u dvije skupine studenata. Sveukupan broj na sva tri e-tečaja je 309 ispitanika koji su sudjelovali u dvije provjere znanja te u izlaznom *anketnom upitniku*. U tablici 33. prikazan je broj ispitanika u provedenim istraživanjima.

Tablica 33. Broj prikupljenih upitnika i pisanih provjera znanja u provedenim istraživanjima

Šifra kolegija	Tečaj za e-učenje	Ustanova na kojoj je provedeno istraživanje	<i>Predtest</i>	<i>Posttest</i>	<i>Anketni upitnik</i>
3D-P	Osvjetljenje i renderiranje	Sveučilište Sjever	55	55	50
PRO-G	Hrpa i stog	Fakultet organizacije i informatike	201	192	182
RPK-G	Multimedija		53	51	51
	Ukupno		309	298	283

P = *predistraživanje*, **G** = *glavno istraživanje*

Iz tabličnog prikaza vidljiva je razlika između *pred* i *posttesta*, te *anketnog upitnika* po broju ispitanih polaznika. Prilikom provođenja *posttest* provjere znanja, u glavnom istraživanju kolegija "**Programiranje 2**", devet studenata nije bilo prisutno, unatoč mogućnosti dolaska u grupu koja im bolje odgovara s obzirom na druge obaveze. Deset studenata unutar kolegija "**PRO**" i pet studenata unutar kolegija "**3D**", nije u potpunosti ispunilo *anketni upitnik* te se nisu koristili u analizi rezultata. Unutar kolegija "**Računalom posredovana komunikacija**", samo dvoje studenata nije pristupilo provjeri znanja niti je sudjelovalo u *anketnom upitniku*.

Podjela ispitanika u *eksperimentalnu* i *kontrolnu* grupu

Ispitanici su tijekom studijskog semestra evidentirani u grupama koje su sami birali. Postojeća raspodjela je prihvaćena te su studenti **jedne grupe** na laboratorijskim **vježbama** iz određenog kolegija ujedno i jedna grupa u istraživanju. Drugo dodatno grupiranje nije korišteno za vrijeme provođenja eksperimenta. Temeljem bodova iz *predtesta* računala se prosječna vrijednost, standardna devijacija te statistička značajnost između grupa. Grupe su uparene **ne prema redoslijedu** pristupanja provjeri znanja, već prema **statističkoj razlici**, gdje je naglasak na tome da između uparenih grupa **ne postoji statistička značajna razlika**. Cilj je upariti *eksperimentalnu* i *kontrolnu* grupu ispitanika kako bi se osigurali **podjednaki početni** uvjeti za ispitivanje mogućeg daljnjeg pomaka u znanju, koji će biti mjeren *posttest* provjerom znanja.

Za potrebe *predistraživanja* koje je provedeno nad ispitanicima koji su uključeni u kolegij "3D modeliranje" (N=55), uparene su sljedeće grupe ispitanika:

❖ **G1** i **G2**, $N_{G1} = 15$; $N_{G2} = 13$; $M_{G1} = 14,53$; $M_{G2} = 13,31$; $t = 0,79$; $p = 0,4318$

❖ **G4** i **G3**, $N_{G4} = 13$; $N_{G3} = 14$; $M_{G4} = 17,69$; $M_{G3} = 17,29$; $t = 0,20$; $p = 0,8374$

gdje su *eksperimentalne* grupe ispitanika: **G1** i **G4**, a *kontrolne* grupe ispitanika: **G2** i **G3**.

Za *prvo glavno istraživanje* koje je provedeno nad ispitanicima koji su uključeni u kolegij "Programiranje 2" (N=201), uparene su sljedeće grupe ispitanika:

❖ **G2** i **G8**, $N_{G2} = 15$; $N_{G8} = 15$; $M_{G2} = 15,60$; $M_{G8} = 14,93$; $t = 0,41$; $p = 0,6826$

❖ **G3** i **G9**, $N_{G3} = 14$; $N_{G9} = 15$; $M_{G3} = 17,29$; $M_{G9} = 14,60$; $t = 1,96$; $p = 0,0595$

❖ **G5** i **G13**, $N_{G5} = 15$; $N_{G13} = 14$; $M_{G5} = 15,00$; $M_{G13} = 15,64$; $t = 0,46$; $p = 0,6481$

❖ **G7** i **G4**, $N_{G7} = 13$; $N_{G4} = 14$; $M_{G7} = 14,92$; $M_{G4} = 13,36$; $t = 1,12$; $p = 0,2724$

❖ **G11** i **G10**, $N_{G11} = 13$; $N_{G10} = 15$; $M_{G11} = 14,31$; $M_{G10} = 15,33$; $t = 0,82$; $p = 0,4171$

❖ **G12** i **G1**, $N_{G12} = 15$; $N_{G1} = 15$; $M_{G12} = 16,00$; $M_{G1} = 17,07$; $t = 0,60$; $p = 0,5483$

❖ **G14** i **G6**, $N_{G14} = 14$; $N_{G6} = 14$; $M_{G14} = 15,71$; $M_{G6} = 15,71$; $t = 0,00$; $p = 1,0000$

od kojih su *eksperimentalne* grupe ispitanika: **G2**, **G3**, **G5**, **G7**, **G11**, **G12**, **G14**, a *kontrolne* grupe ispitanika: **G1**, **G4**, **G6**, **G8**, **G9**, **G10**, **G13**.

Za potrebe *drugog glavnog istraživanja* koje je provedeno nad ispitanicima koji su uključeni u kolegij "Računalom posredovana komunikacija" (N=46), uparene su

❖ **G1** i **G2**, $N_{G1} = 23$; $N_{G2} = 23$; $M_{G1} = 21,91$; $M_{G2} = 20,91$; $t = 1,04$; $p = 0,3029$

od kojih je **G1** ujedno i *eksperimentalna* grupa ispitanika. U ovom slučaju kreirane su samo dvije grupe ispitanika zato što su dvije i vođene unutar kolegija "RPK".

5.6. SADRŽAJ E-TEČAJEVA

U ovom poglavlju navode se nastavne teme koje su korištene u pojedinom e-tečaju.

5.6.1. Pilot e-tečaj "Osvjetljenje i renderiranje"

Teme / sadržaji obuhvaćeni pilot e-tečajem "Osvjetljenje i renderiranje" kolegija "3D modeliranje" (3D) prikazani su na slici 33. i navode su u nastavku ove disertacije:

- **Mental ray sustav za renderiranje** – poglavlje opisuje pojam *Mental ray*, mogućnosti osvjetljenja, osnovne postavke, načine uključivanja *Mental ray*a u scenu i sl.
- **Raytrace i Depth Map sjene** – poglavlje obrađuje dva tipa generiranja sjena unutar programskog alata, osnovne razlike, prednosti i nedostatke, te odnos kvalitete i brzine.
- **Globalno osvjetljenje** – poglavlje definira fotone svjetla, odbijanje od površine, postavke refleksije i refrakcije simuliranih svjetlosnih zraka, potrebu i korištenje mape fotona i dr.
- **Final Gathering (FG) sustav** – poglavlje opisuje sustav kojim se regulira raspršenost svjetla oko modela u sceni, princip kreiranja, pohranjivanja i korištenja *FG* mape i sl.
- **Image-Based Lighting** – poglavlje obrađuje načine na koje se *IBL* može koristiti kao izvor svjetla, objašnjava *HDR* tip fotografija, kako nastaju te njihove prednosti i nedostatke.
- **Osnovno renderiranje** – poglavlje definira osnovni pristup renderiranju, najčešće postavke, korištenje materijala i modela sjenčanja, rad s kamerama, odabir razlučivosti i sl.
- **Napredno renderiranje** – poglavlje se nastavlja na *Image-Based Lighting* i osvjetljenje pomoću *HDR* fotografije, objašnjava renderiranje u slojevima, obradu i kompoziciju slika.

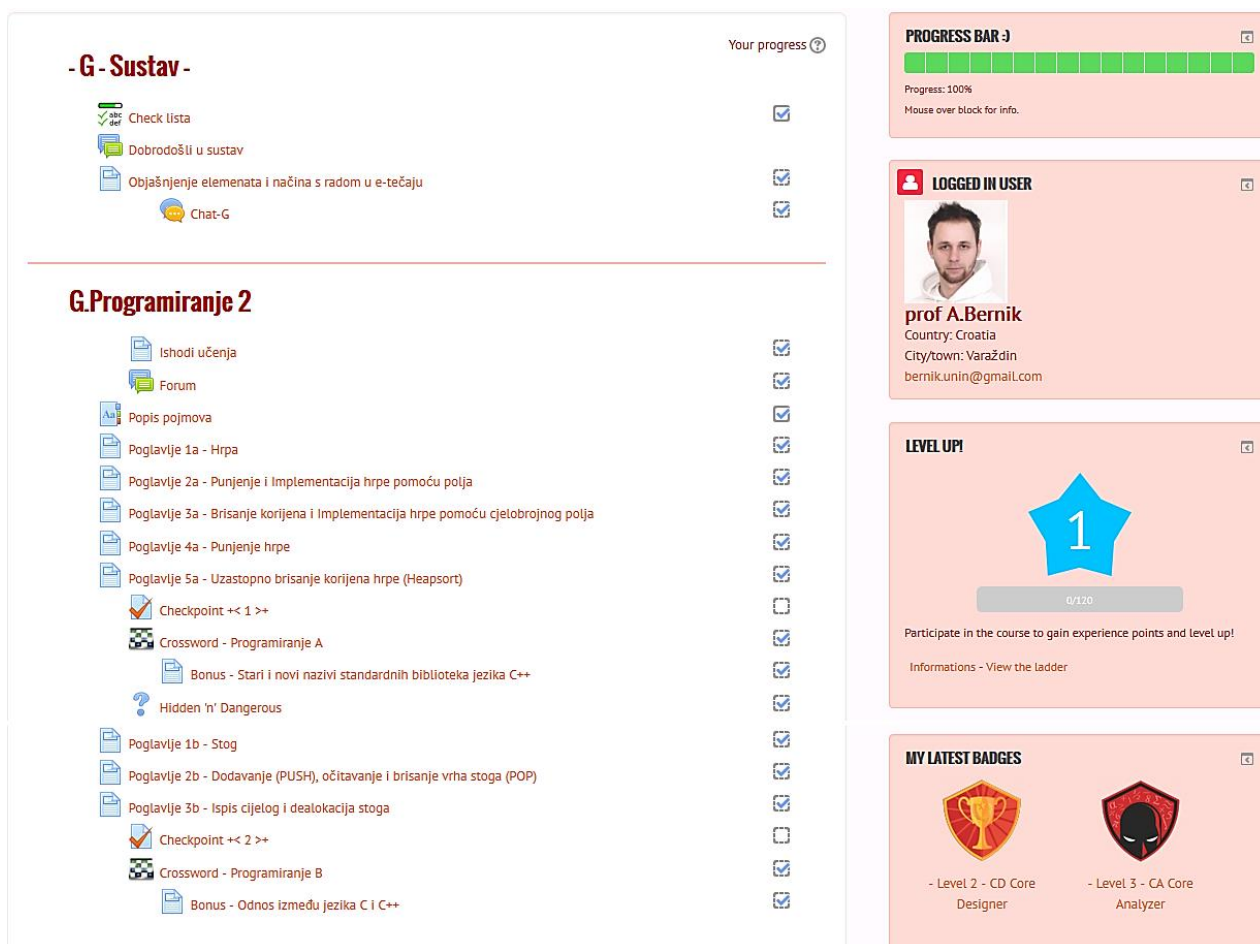
The image shows a course interface. On the left, a list of course materials is displayed under the heading "Maya - Osvjetljenje i renderiranje". The list includes: "Ishodi učenja - Osvjetljenje i renderiranje", "Forum - Osvjetljenje i renderiranje", "Poglavlje - Mental ray", "Video - Osnove osvjetljenja", "Video - Indirect Light 1", "Video - Indirect Light 2", "Poglavlje - Osvjetljenje i renderiranje", "Izazov - 5 Osvjetljenje", "Crossword 3D - Teksturiranje", "Bonus - Life after PI", "Video - Osvjetljenje i renderiranje", "Video - Mental Ray", "Video - Maya i Keyshot", "Poglavlje - Maya Software", and "Izazov - 6 Renderiranje". To the right of this list is a "Your progress" section with a series of checkboxes, some of which are checked. On the right side of the interface, there is a user profile card for "Andrija Bernik, prof" with details: Country: Croatia, City/town: Varaždin, and email: bernik.unin@gmail.com. Below the profile is a "MY LATEST BADGES" section stating "You have no badges to display". At the bottom right, there is a "LEVEL UP!" section showing a blue star with the number "1" and a progress bar at "0/120".

Slika 33. Prikaz strukture i dijela e-tečaja "Osvjetljenje i renderiranje" kolegija "3D"

5.6.2. Eksperimentalni e-tečaj "Hrpa i stog"

Sadržaji isto obuhvaćeni prvim *eksperimentalnim* tečajem "Hrpa i stog" kolegija "Programiranje 2" (PRO) prikazani su na slici 34. i navode su u nastavku ove disertacije:

- **Hrpa** – poglavlje opisuje pojam hrpe, objašnjava se memorijski upravljač, nadređeni i podređeni čvorovi, način implementacije pomoću polja i dr.
- **Punjenje i implementacija hrpe pomoću polja** – poglavlje obrađuje postupak punjenja hrpe, implementaciju na primjeru, objašnjava se indeks nadređenog i podređenog čvora.
- **Brisanje korijena i implementacija hrpe pomoću cjelobrojnog polja** – poglavlje definira brisanje korijena hrpe, *Heapsort* algoritam sortiranja, pokazivač hrpe i dr.
- **Punjenje hrpe** – poglavlje opisuje postupak punjenja hrpe pomoću *main()* funkcije, opisuje indeks unesenog elementa, korištenje pomoćnog elementa "*pom*", te izračunavanje nadređenog čvora.
- **Uzastopno brisanje korijena hrpe (*Heapsort*)** – poglavlje objašnjava sortiranje uzastopnim brisanjem korijena hrpe kroz primjer, while iteraciju, zamjenu mjesta čvorova.
- **Bonus - Stari i novi nazivi standardnih biblioteka jezika C++** – bonus poglavlje opisuje i nabroja promjene kod standardnih biblioteka poput *ifstream*, *io manip*, *string*, *cmath*, *cstdio*. Bonus poglavlje dostupno je korisnicima samo ako su zadovoljili ranije definirane kriterije e-tečaja. Kriteriji su studentu objašnjeni u e-tečaju unutar cjeline "Dobrodošli u sustav" > "Kriteriji i mogućnosti za napredovanje!"
- **Stog** – poglavlje definira pojam stoga, osnovne operacije nad stogom, ubacivanje, očitavanje i izbacivanje elemenata s vrha stoga, te način implementiranja stoga.
- **Dodavanje (*PUSH*), očitavanje i brisanje vrha stoga (*POP*)** – poglavlje definira dodavanje, očitavanje i brisanje elementa stoga kroz odvojene primjere.
- **Ispis cijelog i dealokacija stoga** – poglavlje obrađuje razlike između ispisa stoga i vezane liste. Proces je objašnjen kroz praktičan primjer kao i dealokacija stoga.
- **Bonus - Odnos između jezika C i C++** – bonus poglavlje opisuje odnose između strukturno-orijentiranih i objektno-orijentiranih programskih jezika, te objektnog programiranja kroz praktične primjere. Bonus poglavlje dostupno je nakon zadovoljavanja unaprijed definiranih kriterija. Slika e-tečaja "Hrpa i stog" naveden je u nastavku rada na slici 34.



Slika 34. Prikaz strukture i dijela e-tečaja "Hrpa i stog" kolegija "PRO"

5.6.3. Eksperimentalni e-tečaj "Multimedija"

Sadržaji obuhvaćeni drugim *eksperimentalnim* tečajem "Multimedija" kolegija "Računalom posredovana komunikacija" (RPK) prikazani su na slici 35. i navedeni su u nastavku rada:

- **Tekst** – poglavlje opisuje pojam teksta, ugradnju teksta u računalo, korištenje teksta kod multimedije, dizajn teksta, odabir fontova, uporabu boja i navigacijskih izbornika.
- **Grafika** – poglavlje definira pojam grafike, podjelu na vektorsku i rastersku grafiku, formate zapisa i pohranu grafike, te uključuje tablični prikaz spomenutih formata.
- **Zvuk** – poglavlje obrađuje pojam zvuka, frekvencije i njihove granice čujnosti, MIDI datoteke, datoteke u valnom obliku, MPEG komprimiranje zvuka i dr.
- **Bonus – Boja** – poglavlje definira RGB i CMYK sustav boja na praktičnom primjeru, palete i dubinu boja, te probleme kod tranzicije boja i prikazivanje boja u HTML-u.
- **Bonus – Ostali pojmovi** – poglavlje opisuje sljedeće pojmove: Vizualna komunikacija, grafički dizajn, digitalna kompetencija i ključni elementi iste. Oba bonus poglavlja dostupna su korisnicima samo ako su zadovoljili ranije definirane kriterije e-tečaja.

Kriteriji su studentu objašnjeni u e-tečaju unutar cjeline "Dobrodošli u sustav" > "Kriteriji i mogućnosti za napredovanje!"

- **Video** – poglavlje obrađuje pojam video zapisa, analogan i digitalan video zapis, NTSC i PAL standarde, komprimiranje videa, opis formata poput MPEG, AVI, WMV, DivX.
- **Animacija** – poglavlje definira pojam animacije, korištenje iste u multimediji, vrste i principe animacije, tehnike različitih stilova animiranja, te formate datoteka animacije.
- **Hipermedija i hipertekst** – poglavlje obrađuje pojmove poput hiperteksta, hipermedije i interaktivnosti, te opisuje razine interaktivnosti, strukturu navigacije i dr.
- **Bonus - Primjena teksta na webu** – poglavlje opisuje HTML format i odnos prema fontovima uz naglasak na preporuke koje su navedene u obliku tabličnog prikaza.
- **Bonus - Grafika za web** – poglavlje opisuje PNG, SVG i GIF formate zapisa grafike, daje prikaz brzine i kvalitete iscrtavanja, te tabličnu usporedbu GIF i JPEG formata.
- **Bonus - Primjena zvuka na webu** – poglavlje obrađuje tri pojma: preuzimanje zvuka, zvukovna podloga web stranica i Streaming audio bez lokalnog pohranjivanja zvuka.
- **Bonus - Primjena videa na webu** – poglavlje opisuje procese pohranjivanja videa, uključivanja videa, Streaming video zapisa, te ističe tablični prikaz formata za Web.
- **Bonus - Primjena animacije na webu** – poglavlje opisuje Flash animaciju, animirane GIF-ove, te daje nekoliko preporuka kod primjene animacije na Webu. Navedena bonus poglavlja dostupna su samo nakon zadovoljavanja unaprijed definiranih kriterija.

The screenshot displays the user interface of an e-learning system. On the left, there are two main navigation menus: '- G - Sustav' and '- G - RPK'. The '- G - Sustav' menu includes a checklist with items like 'Dobrodošli u sustav' and 'Objašnjenje elemenata i načina s radom u e-tečaju', along with a 'Chat-G' button. The '- G - RPK' menu lists various course materials such as 'Ishodi učenja', 'Forum', 'Popis pojmova', 'Multimedijalni elementi', 'Poglavlje 1a - Tekst', 'Poglavlje 1b - Grafika', 'Poglavlje 1c - Zvuk', 'Checkpoint << 1 >>', 'Crossword - RPK A', 'Bonus - Boja', 'Bonus - Ostali pojmovi', 'Poglavlje 2a - Video', and 'Poglavlje 2b - Animacija'. On the right side, there are three panels: 'PROGRESS BAR - J' showing a progress bar and a button for 'Overview of students'; 'LOGGED IN USER' showing the user's profile for 'Andrija Bernik, prof' with details like 'Country: Croatia', 'City/town: Varaždin', and 'bernik.unin@gmail.com'; and 'LEVEL UP!' showing a star with the number '1' and a progress bar for '0/120'.

Slika 35. Prikaz strukture i dijela e-tečaja "Multimedija" kolegija "RPK"

Sva tri istraživanja provedena su unutar 25 radnih dana. Sedam dana rezervirano je za upoznavanje ispitanika s planom istraživanja, te za provedbu *predtest* provjere znanja kojom se osigurava **ravnopravno uparivanje** studenata u *eksperimentalnu* i *kontrolnu* grupu. Minimalno **14 dana** namijenjeno je studentima za samostalno proučavaju nastavnih materijala. Navodi se minimalno 14 dana iz razloga što se u tom tjednu koji je slijedio provodila *posttest* provjera znanja, te su studenti do provjere znanja mogli koristiti *eksperimentalni* tj. *kontrolni* e-tečaj. Nastavni materijali koji se nalaze unutar e-tečaja (Osvjetljenje i renderiranje; Hrpa i stog; Multimedija), ne obrađuju se sa nastavnikom u bilo kojem drugom obliku. Jedina komunikacija koja je moguća po pitanju navedenih nastavnih materijala, iz *gemificiranog* ili *kontrolnog* e-tečaja, je kroz putem sinkrone ili asinkrone komunikacije koja je u e-tečaju omogućena.

Uspjeh studenata se unutar e-tečaja kolegija "**3D modeliranje**", "**Programiranje 2**" i kolegija "**Računalom posredovana komunikacija**" nagrađivao dodatnim bodovima s obzirom na studentovu aktivnost.

- U okviru kolegija "**3D modeliranje**" studenti su imali mogućnost osvojiti dodatna 3 boda. Studenti koji su sudjelovali u cjelokupnom istraživanju dobili su 3 boda, studenti koji u potpunosti nisu sudjelovali u istraživanju (sudjelovali u *predtestu*, ali ne i u ostalim aktivnostima) dobili su 1 bod, studenti koji uopće nisu sudjelovali izostavljeni su iz dodatnog bodovanja.
- U okviru kolegija "**Programiranje 2**", 25% studenata s najboljim rezultatom u *eksperimentalnoj* i *kontrolnoj* skupini dobilo je 4 boda. Sljedećih 25% studenata obje skupine dobilo je 3 boda, sljedećih 25% studenata obje skupine dobilo je 2 boda i na kraju, zadnja skupina ispitanika koja je imala najslabije rezultate dobila je po 1 bod.
- U okviru kolegija "**Računalom posredovana komunikacija**", studenti su dobivali 1 do 5 bodova za ocjenu ako su koristili e-tečajeve i pristupili *posttest* provjeri znanja i *anketnom upitniku* motivacije i zadovoljstva, a 0 bodova ako nisu. Ukupno su za ocjenu iz kolegija dobivali 0-100 bodova, tj. rad s e-tečajem donosio je 5% od ukupnih bodova za ocjenu. Bodovanje za ocjenu je provedeno na temelju sljedeće raspodjele: 88-100 bodova = izvrstan (5); 73-87 bodova = vrlo dobar (4); 59-72 bodova = dobar (3); 50-59 bodova = dovoljan (2).

5.7. POSTUPCI I AKTIVNOSTI U PRIPREMI PROVOĐENJA ISTRAŽIVANJA

Osim već spomenutog uvjeta koji se odnosi na IT resurse potrebne za provođenje istraživanja (poglavlje 4.2. i 4.3.), bitno je osigurati nastavne materijale, pripremiti studente za istraživanje te korigirati postojeće nastavne aktivnosti.

Prvi korak u pripremi provođenja istraživanja odnosi se na pronalazak i analizu stručne i znanstvene literature za kreiranje konceptualnog modela. Kreira se popis *gemificiranih* elemenata koji su pogodni za *gemificirani* Moodle sustav, koji se nalazi u tablici 24. Izrađen je **konceptualan gemificirani model** eRIOOS (**e**lementi **r**ačunalnih **i**gara u **o**nline **o**brazovnom **s**ustavu).

Drugi korak odnosi se na **odabir materijala** koji su dovoljno jednostavni kako bi se mogli realizirati u vremenskom okviru od minimalno 14 dana, a ipak da zadovoljavaju težinom odabranu skupinu ispitanika. Odabrani nastavni materijali navedeni su unutar potpoglavlja 5.6.1., 5.6.2. i 5.6.3. Nastavni materijali se uređuju u oblik koji je pogodan za *eksperimentalni* i *kontrolni* e-tečaj. Radi se o **digitalizaciji sadržaja**, s obzirom na to kako su nastavni materijali preuzeti iz osnovne literature za kolegije koji su tiskani u obliku knjiga. Nastavni materijali su sadržavali digitalan tekst, digitalnu fotografiju / ilustraciju te video zapise. Nastavni materijali u e-tečajevima, za svako istraživanje posebno, za *eksperimentalnu* i *kontrolnu* skupinu su **identični** kao i njihov **redoslijed pozicioniranja**. Ovaj korak **identičan je** za oba e-tečaja.

Treći korak bio je integriranje nastavnog sadržaja s kreiranim *klasičnim* i *gemificiranim* e-tečajevima. Ovaj korak **nije identičan** za oba sustava zato što studenti, u *klasičnom* e-tečaju, na raspolaganju imaju samo digitalan tekst, popratne fotografije / ilustracije te video zapise. Studenti u *eksperimentalnom* e-tečaju imaju osim digitalnog teksta, popratnih fotografija / ilustracija i video zapisa imaju još i sustav *napredovanja*, *top-ljestvice postignuća*, *skriveno zabavne* dodatke u obliku *računalnih igara* ili *dinamične promjene* u grafičkom dijelu e-tečaja, *uvodnu priču*, *zadatke za ponavljanje znanja* i sl. Svi elementi koji su uključeni u *eksperimentalan* e-tečaj (pogledati tablicu 24.) moraju biti povezani s nastavnim materijalima. Navedeno je postignuto kroz **pravila napredovanja** te **uvjetovanje pristupa** određenim dijelovima sustava, isto kao i **praćenjem aktivnosti i uspješnosti** studenata.

Četvrti korak odnosi se na pripremu studenata za istraživanje. Sa studentima je održano uvodno predavanje u kojemu se objasnio **princip** provođenja istraživanja (**provjera predznanja, grupiranje, ulazak u sustav, konačna provjera znanja, te prikupljanje mišljenja o eksperimentu**).

U tu su svrhu kreirane *predtest* i *posttest* provjere znanja, kao i **anketni upitnik motivacije i zadovoljstva** u kojem se analiziraju ključni elementi e-tečaja, te ostali pokazatelji vezani za *gemificirani* Moodle sustav. Objašnjeno je i **vremensko trajanje** istraživanja koje traje između 21 i 25 dana gdje se studentima osigurava pristup u *eksperimentalan* ili *kontrolni* e-tečaju u trajanju od minimalno 14 dana. Objasnio se kako je istraživanje dobrovoljno i kako za one koji žele sudjelovati slijedi nagrada od nekoliko bodova. Ovaj korak **identičan je** za oba sustava.

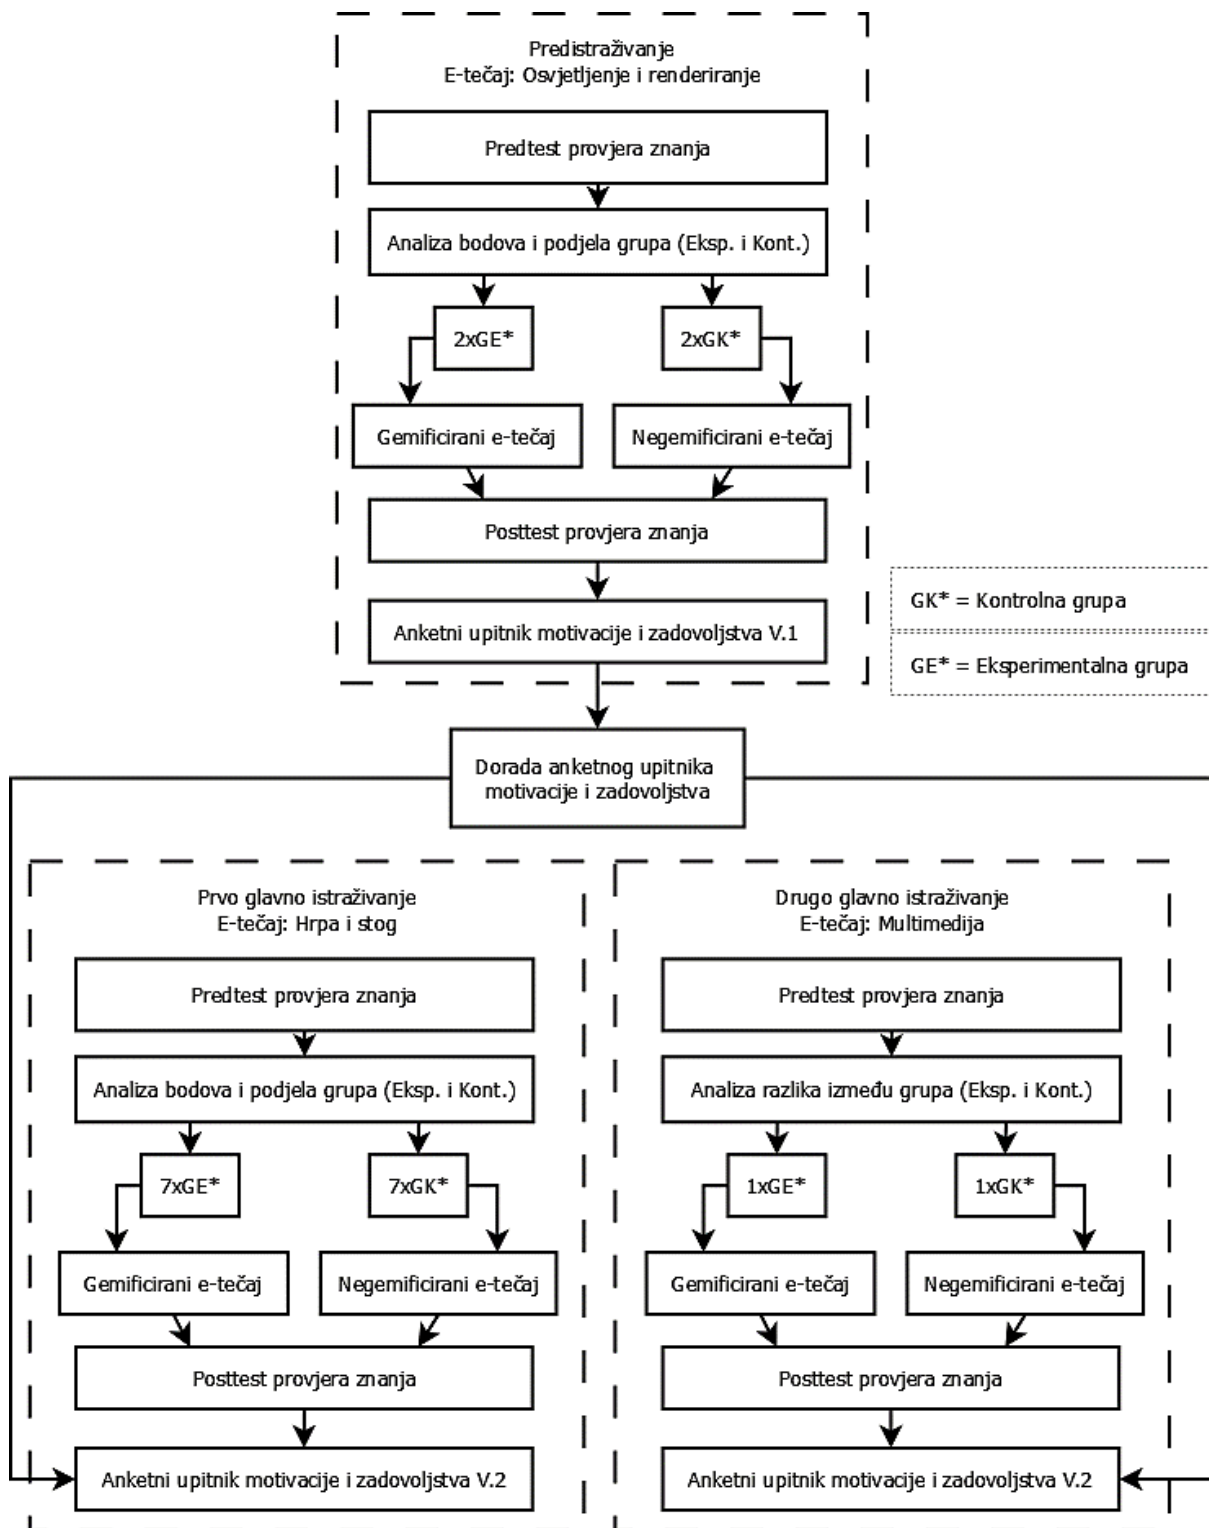
Peti korak odnosi se na izvođenje kolegija gdje se **nastavni materijali** koji su uključeni u istraživanje **izostavljaju** iz **ostalih oblika tradicionalne nastave** (predavanja, auditorne vježbe, laboratorijske vježbe, konzultacije). Istraživački nastavni materijal namijenjen je za korištenje isključivo u *eksperimentalnom* ili *klasičnom* e-tečaju. Sva komunikacija o navedenim nastavnim sadržajima moguća je **isključivo unutar e-tečaja** putem **sinkrone** (eng. *chat*) ili **asinkrone** (eng. *forum*) komunikacije. Ovaj korak **identičan je** za oba sustava.

Osim navedenih radnji bitno je spomenuti mogućnosti koje studenti za pojedini tečaj imaju.

- Unutar *klasičnog* e-tečaja studenti su mogli pristupiti digitalnim nastavnim sadržajima koji su prikazani putem teksta, fotografije / ilustracije te putem video zapisa. Studenti na raspolaganju imaju **inicijalan izgled Moodle sustava** bez ikakvog uljepšavanja ili uklanjanja elemenata. Studenti imaju uključen forum koji služi za informiranje. **Ništa drugo** od elemenata računalnih igara nije uključeno u sustav. *Klasičan* e-tečaj **nema sustav nagrađivanja** niti mogućnost pregledavanja uspješnosti ostalih polaznika. Nema mogućnost provjere znanja niti pruža bilo kakve povratne informacije osim u vidu komunikacije. Sastavni dio *klasičnog* e-tečaja su i aktivnosti pod nazivima "Nove obavijesti", "Buduća događanja", "Nedavna aktivnost", kao i "Navigacija" te "Osnovne postavke sustava".
- Unutar *gemificiranog* e-tečaja studenti su mogli pristupiti digitalnim nastavnim sadržajima koji su prikazani putem teksta, fotografije / ilustracije te putem video zapisa. Studenti na raspolaganju imaju **sve elemente** koji se navode u **koraku 3.** ovog poglavlja te u **tablici 24.** Neki od njih su npr. *Priča, Epsko značenje, Vizualan prikaz svih obveza, Nelinearno korištenje nastavnih materijala, Top lista i poredak studenata, Elementi iznenađenja unutar e-tečaja, Edukativne igre* i dr. Zbog redundantnosti popis elemenata neće se ponavljati unutar ovog dijela doktorske disertacije.

6. REZULTATI ISTRAŽIVANJA

U ovom poglavlju opisana su **tri odvojena** istraživanja pomoću kojih se potvrđuje **utjecaj elemenata računalnih igara** na studente u visoko školskim institucijama. Slika strukture empirijskog istraživanja prikazuje se na slici 36. ovog doktorskog rada.



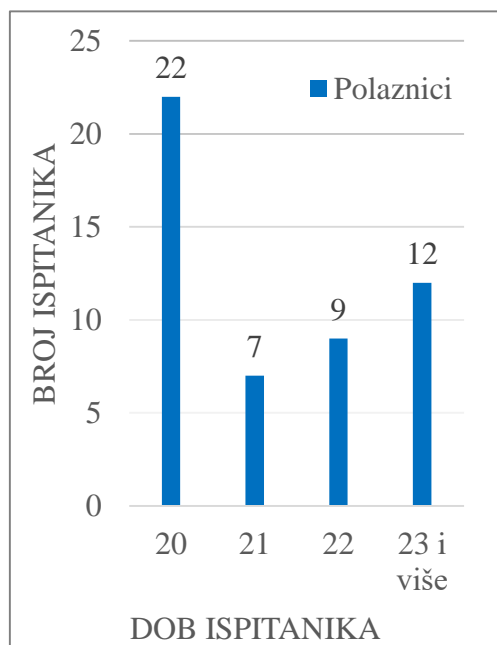
Slika 36. Grafički prikaz strukture empirijskog istraživanja ovog doktorskog rada

Predistraživanje je provedeno na drugoj godini preddiplomskog interdisciplinarnog stručnog studija **Sveučilišta Sjever**, odjela Multimedije, oblikovanja i primjene u Varaždinu, akademske godine 2014./2015. **Prvo i drugo glavno istraživanje** provedeno je na drugoj godini preddiplomskog studija i prvoj godini diplomskog studija Informacijskih sustava, **Fakulteta organizacije i informatike** u Varaždinu, akademske godine 2015./2016.

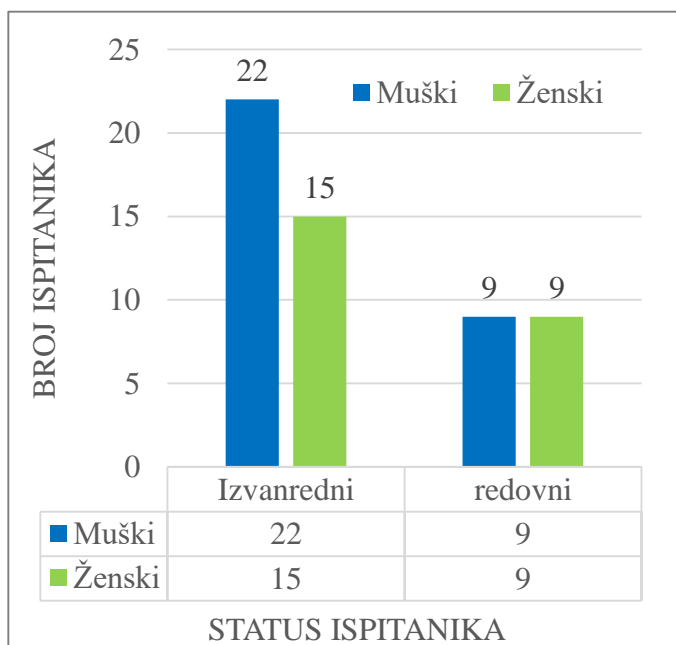
Instrumenti istraživačkog rada, **opisi** ispitanika i **sadržaji** e-tečajeva objašnjeni su u **poglavlju 5**. te će se u ovom poglavlju ukratko ponoviti i povezivati s rezultatima istraživanja.

6.1. PREDISTRAŽIVANJE: E-TEČAJ "OSVJETLJENJE I RENDERIRANJE"

Ispitanici u **predistraživanju** bili su studenti druge godine Sveučilišta Sjever koji su pohađali izborni kolegij "3D modeliranje" i dobrovoljno su sudjelovali u ovom istraživanju. **Ukupan broj** ispitanika je bio **55**, od čega je njih 33% bilo redovnih, a 67% izvanrednih studenata. Ispitanici su bili podijeljeni u **četiri skupine po 15 studenata** u grupi. Od navedenog ukupnog broja ispitanika, 44% je bilo ženskog, a 56% muškog spola. Prosječna dob ispitanika bila je 20 godina. *Anketni upitnik* u cijelosti je ispunilo **50** studenata. Uvid u strukturu ispitanika nalazi se na slikama 37. i 38.



Slika 37. Dob ispitanika kolegija "3D modeliranje" (N=50)



Slika 38. Status ispitanika kolegija "3D modeliranje" (N=55)

6.1.1. *Predtest* analiza rezultata u provedenom *predistraživanju*

Polaznici kolegija "3D modeliranje", e-tečaja "Osvjetljenje i renderiranje" primili su upute kako pristupiti ispunjavanju *predtest provjere znanja* kojom se provjeravalo predznanje studenata. Studenti su, prema vježbama, podijeljeni u četiri grupe i to dvije *eksperimentalne* i dvije *kontrolne* grupe. *Predtestom* se provjeravala statistička razlika između grupa.

Tablica 34. Usporedni prikaz *eksperimentalne* i *kontrolne* grupe nakon *predtesta* za provjeru znanja

Grupa 1 - Eksperimentalna grupa (G1) N = 15			Grupa 4 - Eksperimentalna grupa (G4) N = 13		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
1	13	40,63	43	10	31,25
2	24	75,00	44	17	53,13
3	8	25,00	45	23	71,88
4	15	46,88	46	14	43,75
5	11	34,38	47	15	46,88
6	16	50,00	48	13	40,63
7	19	59,38	49	15	46,88
8	14	43,75	50	28	87,50
9	11	34,38	51	21	65,63
10	16	50,00	52	20	62,50
11	14	43,75	53	25	78,13
12	14	43,75	54	18	56,25
13	11	34,38	55	11	34,38
14	9	28,13			
15	23	71,88			
Prosječni bodovi grupe: 14,533			Prosječni bodovi grupe: 17,692		
Grupa 2 - Kontrolna grupa (G2) N = 13			Grupa 3 - Kontrolna grupa (G3) N = 14		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
16	12	37,50	29	9	28,13
17	13	40,63	30	26	81,25
18	9	28,13	31	16	50,00
19	8	25,00	32	14	43,75
20	10	31,25	33	16	50,00
21	18	56,25	34	19	59,38
22	14	43,75	35	18	56,25
23	11	34,38	36	18	56,25
24	14	43,75	37	20	62,50
25	14	43,75	38	10	31,25
26	18	56,25	39	14	43,75
27	17	53,13	40	17	53,13
28	15	46,88	41	22	68,75
			42	23	71,88
Prosječni bodovi grupe: 13,307			Prosječni bodovi grupe: 17,285		

Tablica 35. Rezultati *predtesta* za sve ispitanike *eksperimentalne* (G1, G4) grupe (N=28)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	16,00	5,19	11	8-28

Rezultati *predtesta* za provjeru znanja kod **svih ispitanika** grupiranih unutar *eksperimentalne grupe* u provedenom *predistraživanju*, prikazani su u tablici 35. Prosječna vrijednost bodova koju je grupa postigla iznosi 16,00 uz standardnu devijaciju od 5,19. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 11. Raspon bodova kreće se od minimalno 8 do maksimalno 28.

Tablica 36. Rezultati *predtesta* za sve ispitanike *kontrolne* (G2, G3) grupe (N =27)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	15,37	4,48	14	8-26

Navedeni su rezultati *predtesta* za provjeru znanja kod **svih ispitanika** grupiranih unutar *kontrolne grupe*. Od ukupnog broja bodova, *kontrolna* grupa je ostvarila prosječnu vrijednost bodova u iznosu od 15,37 uz standardnu devijaciju od 4,48. Najčešći iznos (Mod) sakupljenih bodova iznosi 14. Raspon bodova koji su ispitanici ostvarili iznosi od 8 do 26.

Tablica 37. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta eksperimentalne* (G1) grupe (N=15) i *kontrolne* (G2) grupe (N=13)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G1	15	14,53	4,63	0,79	0,4318
G2	13	13,31	3,25		

t = odnos između prosječnih vrijednosti *eksperimentalne* i *kontrolne* grupe, te standardne pogreške razlike.

p = signifikantnost, tj. što je p vrijednost manja to je manja i empirijski utvrđena vjerojatnost odbacivanja istinite hipoteze i obratno.

Tablica 37. prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja u provedenom *predistraživanju*. Izračun se temelji na usporedbi prve *eksperimentalne* (G1) i prve *kontrolne* (G2) grupe. Intermedijalna **t vrijednost** iznosi **0,79**. Izračunata **p vrijednost** iznosi **0,43** čime se može zaključiti kako između prve *eksperimentalne* (G1) i prve *kontrolne* (G2) grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*.

Tablica 38. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta eksperimentalne (G4)* grupe (N=13) i *kontrolne (G3)* grupe (N=14)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G4	13	17,69	5,47	0,20	0,8374
G3	14	17,29	4,71		

U tablici 38. prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja u provedenom *predistraživanju*. Izračun se temelji na usporedbi druge *eksperimentalne (G4)* grupe i druge *kontrolne (G3)* grupe ispitanika. Intermedijalna **vrijednost t** iznosi **0,20**. Izračunata **p vrijednost** iznosi **0,83** čime se može zaključiti kako između navedenih ispitanika *eksperimentalne (G4)* i *kontrolne (G3)* grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*.

Tablica 39. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta svih ispitanika eksperimentalne (G1, G4; N=28)* i *kontrolne (G2, G3; N=27)* grupe

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G1, G4	28	16,00	5,19	0,48	0,6328
G2, G3	27	15,37	4,48		

U tablici 39. prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja u provedenom *predistraživanju*. Izračun se temelji na usporedbi **svih ispitanika eksperimentalne (G1, G4)** grupe te **svih ispitanika kontrolne (G2, G3)** grupe. Intermedijalna **vrijednost t** iznosi **0,48**. Izračunata **p vrijednost** iznosi **0,63** čime se može zaključiti kako između svih ispitanika *eksperimentalne (G1, G4)* grupe te svih ispitanika *kontrolne (G2, G3)* grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*.

Temeljem rezultata *predtesta*, zaključuje se kako su grupe **međusobno podjednake** te se **ukazuje na mogućnost** dolaska do statistički značajnih razlika u *eksperimentalnom* sustavu, obzirom na prosječne rezultate bodova koje će studenti ostvariti u *posttest* provjeri znanja. *Eksperimentalna* grupa izložena je e-tečaju koji je upotpunjen s elementima računalnih igara, dok je *kontrolna* izložena klasičnom e-tečaju u kojima se nastavni sadržaji međusobno ne razlikuju. U *posttest* provjeri znanja mjeri se usvojenost znanja polaznika s obzirom na nastavne sadržaje *gemificiranog* i *negemificiranog* e-tečaja.

6.1.2. Posttest analiza rezultata u provedenom predistraživanju

Polaznici kolegija "3D modeliranje", primili su upute kako pristupiti ispunjavanju *posttesta* kojim se provjeravalo znanje studenata iz nastavnih sadržaja obuhvaćenih e-tečajem "Osvjetljenje i renderiranje". *Eksperimentalne* i *kontrolne* grupe nisu bile mijenjane s obzirom na raniju postignutu jednakost između grupa.

Tablica 40. Usporedni prikaz *eksperimentalne* i *kontrolne* grupe nakon *posttesta* za provjeru znanja

Grupa 1 - Eksperimentalna grupa (G1) N = 15			Grupa 4 - Eksperimentalna grupa (G4) N = 13		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
1	14	43,75	43	21	65,63
2	29	90,63	44	26	81,25
3	15	46,88	45	18	56,25
4	26	81,25	46	24	75,00
5	18	56,25	47	12	37,50
6	14	43,75	48	9	28,13
7	28	87,50	49	21	65,63
8	27	84,38	50	30	93,75
9	23	71,88	51	20	62,50
10	16	50,00	52	25	78,13
11	17	53,13	53	29	90,63
12	12	37,50	54	23	71,88
13	19	59,38	55	21	65,63
14	23	71,88			
15	25	78,13			
Prosječni bodovi grupe: 20,400			Prosječni bodovi grupe: 21,461		
Grupa 2 - Kontrolna grupa (G2) N = 13			Grupa 3 - Kontrolna grupa (G3) N = 14		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
16	15	46,88	29	5	15,63
17	12	37,50	30	21	65,63
18	13	40,63	31	23	71,88
19	17	53,13	32	15	46,88
20	14	43,75	33	10	31,25
21	20	62,50	34	8	25,00
22	13	40,63	35	17	53,13
23	13	40,63	36	12	37,50
24	17	53,13	37	20	62,50
25	18	56,25	38	9	28,13
26	12	37,50	39	17	53,13
27	16	50,00	40	16	50,00
28	17	53,13	41	19	59,38
			42	24	75,00
Prosječni bodovi grupe: 15,153			Prosječni bodovi grupe: 15,428		

Tablica 41. Rezultati *posttesta* za sve ispitanike *eksperimentalne* (G1, G4) grupe (N=28)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	20,89	5,78	23	9-30

Tablica 41. prikazuje rezultate *posttesta* za provjeru znanja kod svih ispitanika grupiranih unutar *eksperimentalne* grupe. Prosječna vrijednost bodova koju je grupa postigla iznosi 20,89 uz standardnu devijaciju od 5,78. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 23. Raspon bodova kreće se od minimalno 9 do maksimalno 30.

Tablica 42. Rezultati *posttesta* za sve ispitanike *kontrolne* (G2, G3) grupe (N =27)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	15,30	4,50	17	5-24

Rezultati *posttesta* za provjeru znanja kod svih ispitanika grupiranih unutar *kontrolne* grupe, prikazani su u tablici 42. Od ukupnog broja bodova, grupa je ostvarila prosječnu vrijednost bodova u iznosu od 15,30 uz standardnu devijaciju od 4,50. Najčešći iznos (Mod) sakupljenih bodova iznosi 17. Raspon bodova koji su ispitanici ostvarili iznosi od 5 do 24.

Tablica 43. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta* *eksperimentalne* (G1) grupe (N=15) i *kontrolne* (G2) grupe (N=13)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G1	15	20,40	5,74	3,04	0,0053
G2	13	15,15	2,54		

Tablica 43. prikazuje izračun statističke značajnosti na temelju rezultata *posttesta* za provjeru znanja. Izračun se temelji na usporedbi prve *eksperimentalne* (G1) i prve *kontrolne* (G2) grupe. Intermedijalna **t vrijednost** iznosi **3,04**. Izračunata **p vrijednost** iznosi **0,005** čime se može zaključiti, uz mogućnost pogreške od 1%, kako između prve *eksperimentalne* (G1) i prve *kontrolne* (G2) grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*.

Tablica 44. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta eksperimentalne* (G4) grupe (N=13) i *kontrolne* (G3) grupe (N=14)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G4	13	21,46	5,99	2,64	0,0140
G3	14	15,43	5,87		

U tablici 44. prikazuje se izračun statističke značajnosti temeljem rezultata *posttesta* za provjeru znanja. Izračun se odnosi na usporedbu druge *eksperimentalne* (G4) grupe i druge *kontrolne* (G3) grupe ispitanika. Intermedijalna **vrijednost t** iznosi **2,64**. Izračunata **p vrijednost** iznosi **0,01** čime se može zaključiti, uz mogućnost pogreške od 5%, kako između navedenih ispitanika *eksperimentalne* (G4) i *kontrolne* (G3) grupe **postoji statistički značajna razlika**.

Tablica 45. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta svih ispitanika eksperimentalne* (G1, G4; N=28) i *kontrolne* (G2, G3; N=27) grupe

Ispitanici	Broj ispitanika	Prosječna vrijednost M	Standardna devijacija σ	t	p
G1, G4	28	20,89	5,78	3,99	0,0002
G2, G3	27	15,30	4,50		

Tablica 45. prikazuje izračun statističke značajnosti na temelju rezultata *posttesta* za provjeru znanja. Izračun se temelji na usporedbi svih ispitanika *eksperimentalne* (G1, G4) grupe te svih ispitanika *kontrolne* (G2, G3) grupe. Intermedijalna **vrijednost t** iznosi **3,99**. Izračunata **p vrijednost** iznosi **0,0002** čime se može zaključiti, uz mogućnost pogreške od 1%, kako između svih ispitanika *eksperimentalne* (G1, G4) grupe te svih ispitanika *kontrolne* (G2, G3) grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*.

Prosječan broj bodova prije eksperimenta za *eksperimentalnu grupu* iznosio je **16,00**, dok je za *kontrolnu grupu* iznosio **15,37**. Pomoću *predtest provjere znanja*, izračunate su **p vrijednosti** na temelju kojih se vidi kako **između uspoređenih grupa ne postoji statistički značajna razlika**. Navedeni rezultat je važan zbog osiguravanja približno jednakih početnih uvjeta koji se trebaju postići prije provođenja eksperimenta. *Eksperimentalne* grupe pristupile su *eksperimentalnom* e-tečaju, dok su *kontrolne* grupe pristupale klasičnom e-tečaju. Prosječan broj bodova dobiven *posttest provjerom znanja* nakon eksperimenta se za *eksperimentalnu grupu* povećao za **30.5%** te je iznosio **20,89**, dok se za *kontrolnu grupu* smanjio za **0,52%** te je iznosio **15,30**. *Eksperimentalna* grupa ostvarila je **bolji rezultat** za **36,55%**. Pomoću *posttest provjere znanja* izračunate su **p vrijednosti** na temelju kojih se vidi kako **između grupa postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*.

U tablici 46. ove disertacije prikazuje se dodatna analiza **otvorenog tipa** pitanja *posttest* provjere znanja u provedenom *predistraživanju*. Izračunat je prosjek, standardna devijacija, kao i statistička značajnost rezultata. U analizu je uključena varijanta gdje se pitanjima otvorenog tipa (tj. pitanjima esejskog tipa) dodaje veći broj bodova.

Tablica 46. Analiza otvorenog tipa pitanja *posttest* provjere znanja u *predistraživanju*

	Otvoreni tip pitanja (n=6)		Otvoreni tip pitanja (n=6)*	
	Eksp.	Kont.	Eksp.	Kont.
Grupa ispitanika				
Prosjeck bodova	2,79	2,07	5,57	4,15
Stand. devijacija	2,06	1,75	4,12	3,50
t vrijednost	1,38		1,38	
p vrijednost	0,174		0,174	

n = broj pitanja u provjeri znanja,

* = analiza u slučaju izmjene sustava bodova kod pitanja otvorenog tipa

Tablica 46. pokazuje analizu otvorenog tipa pitanja iz *posttest* provjere znanja koja predstavlja dopunu ranije prezentiranih analiza iz **poglavlja 6.1.2.** Vidljivo je kako *eksperimentalna* grupa ispitanika (**Eksp**), koja broji ukupno 28 ispitanika, ima **veći prosječan broj bodova**, isto kao i standardnu devijaciju bodova u odnosu na *kontrolnu* grupu ispitanika (**Kont**), koja broji ukupno 27 ispitanika. **Statistički značajna razlika** između navedenih skupina nije postignuta, no treba imati na umu kako je ovo **izdvojena analiza pitanja otvorenog tipa** (n=6). Statistička značajnost, između navedenih skupina, postignuta je u slučaju **cjelokupne analize posttest provjere** znanja koja broji 32 pitanja.

Već je ranije spomenuto kako svako pitanje ili zadatak u *posttest* provjeri znanja nosi **jedan bod**. U slučaju kada se otvoreni tip pitanja (tj. pitanja esejskog tipa) bodovao s **dva boda**, **statistička značajnost rezultata** nije bila promijenjena isto kao niti drugi pokazatelji koji bi utjecali na promjenu iznesenih zaključaka. **Standardna devijacija** i **prosječna vrijednost** bodova proporcionalno se udvostručuju čime se ne mijenja daljnji tijek analize.

Zbog jednostavnosti prikaza i ranijih izračuna, odlučeno je zadržati postojeći sustav bodovanja gdje svako pitanje nosi jedan bod, bez obzira radi li se o pitanjima otvorenog ili zatvorenog tipa. Rezultat istraživanja se ne mijenja što je i pokazano u tablici 46. gdje je učinjena reparacija bodova iz *predistraživanja*. Izračunata je prosječna vrijednost bodova, isto kao i standardna devijacija, te se utvrdilo kako je rezultat isti prije i poslije izmjene sustava bodovanja (tj. promjene iznosa bodova koji je dodijeljen studentu za točno riješen zadatak ili pitanje).

U nastavku analize, dodaje se još jedan kriterij koji se odnosi na selekciju studenata koji su ostvarili **minimalno 50% ukupnih bodova** u *predtest* provjeri znanja. U provedenom *predtestu predistraživanja* ove doktorske disertacije, sudjelovalo je 55 ispitanika. *Predtest* je brojao 32 pitanja, od kojih su 26 pitanja zatvorenog tipa i 6 pitanja otvorenog tipa. Svako pitanje nosilo je jedan bod i služilo je utvrđivanju studentovog predznanja.

Uz navedenu analizu koja je detaljno prikazana u ovom poglavlju, napravljena je dodatna analiza bodova samo nad ispitanicima koji su zadovoljili dodatni uvjet, koji je vezan za ostvarivanje **minimalno 50% ukupnih bodova** u provedenom *predtestu predistraživanja*. Od ukupnog broja ispitanika, njih 25 zadovoljilo je navedeni uvjet. Iz ranije definiranih grupa uklonjeni su svi studenti koji nisu imali ostvareno minimalno 50% ukupnih bodova, nakon čega su rezultati bodova ponovno analizirani.

Provedena je analiza *posttest* provjere znanja nad pitanjima zatvorenog tipa (ukupno 26 pitanja), nad pitanjima otvorenog tipa (ukupno 6 pitanja), te nad ukupno ostvarenim bodovima (ukupno 32 pitanja). Rezultati su uspoređivani na razini uparenih grupa, koje su i ranije korištene u ovoj doktorskoj disertaciji, isto kao i na skupnoj razini *eksperimentalne* (N=12) i *kontrolne* grupe ispitanika (N=13). U nastavku rada vidljiv je usporedni prikaz navedenih elemenata, isto kao i podjela *posttest rezultata iz predistraživanja*.

Tablica 47. Usporedni prikaz analize odgovora iz *posttest* provjere u *predistraživanju*

	Zatvoreni tip pitanja (uk. broj pitanja = 26)		Otvoreni tip pitanja (uk. broj pitanja = 6)		Ukupni rezultat (uk. broj pitanja = 32)	
	Eksp.	Kont.	Eksp.	Kont.	Eksp.	Kont.
Grupa ispitanika						
Prosjeck bodova	19,42	14,15	4,17	2,62	23,58	16,77
Stand. devijacija	3,80	3,16	1,75	2,02	5,42	5,04
Broj ispitanika	12	13	12	13	12	13
t vrijednost	3,77		2,04		3,26	
p vrijednost	0,001		0,052		0,003	

*Eksp. = *eksperimentalna* grupa, *Kont. = *kontrolna* grupa

Vidljivo je kako su **prosječni bodovi** u sva tri slučaja **veći** kod *eksperimentalne grupe* ispitanika. Standardna devijacija jedino je u slučaju otvorenih pitanja veća kod *kontrolne* grupe ispitanika. Izračunata **p vrijednost** pokazuje kako u drugom slučaju s pitanjima otvorenog tipa postoji granična statistički značajna razlika, koja se može pripisati malom broju ispitanika. U druga dva slučajeve, s pitanjima zatvorenog tipa i kod ukupne analize bodova, izračunata **p vrijednost** pokazuje kako je *eksperimentalna* grupa ispitanika postigla bolji rezultat u odnosu na *kontrolnu* grupu ispitanika koji osigurava **statistički značajnu razliku**.

Dodatna analiza u tablici 47. pokazuje odnos postignutih bodova između ranije uparenih grupa, kao i između studenata koji su u *predtestu predistraživanja* postigli 50% (ili više) od ukupnih bodova. Unutar navedenog prikaza vidljivi su bodovi za pitanja zatvorenog tipa (ukupno 26 pitanja) i otvorenog tipa (ukupno 6 pitanja) koje su studenti ostvarili kroz *posttest* provjeru znanja. **Sve eksperimentalne** grupe imaju **prosječan broj** bodova veći od *kontrolnih* grupa. Unutar tablice 47. navode se i bodovi za sva pitanja *posttest* provjere znanja (ukupno 32 pitanja) te je nad njima provedena t-test analiza. Izračunata **t vrijednost iznosi 3.26**, dok je **p vrijednost 0.003**, čime se zaključuje kako između ispitanika *eksperimentalne* (N=12) i *kontrolne* (N=13) grupe ispitanika **postoji statistički značajna razlika** u korist *eksperimentalne grupe* ispitanika.

U nastavku disertacije navodi se statistička analiza odgovora koji su prikupljeni iz *predtest* i *posttest* provjera znanja u provedenom *predistraživanju*. Izračunata je jedinična težina pitanja, prosječna težina pitanja i standardna devijacija.

Tablica 48. Analiza težine pitanja u provedenom *predtestu predistraživanja*

Pitanje zatvorenog tipa	Broj točnih odgovora (maks. 55 odgovora)	Težina pitanja
1	40	0,73
2	24	0,44
3	31	0,56
4	24	0,44
5	18	0,33
6	19	0,35
7	37	0,67
8	45	0,82
9	47	0,85
10	16	0,29
11	8	0,15
12	21	0,38
13	34	0,62
14	18	0,33
15	51	0,93
16	15	0,27
17	21	0,38
18	14	0,25
19	39	0,71
20	21	0,38
21	7	0,13
22	35	0,64
23	14	0,25
24	20	0,36
25	8	0,15
26	14	0,25
Prosječna težina pitanja:		0,45
Standardna devijacija:		0,23
Pitanje otvorenog tipa	Broj točnih odgovora (maks. 55 odgovora)	Težina pitanja
1	40	0,73
2	29	0,53
3	44	0,80
4	44	0,80
5	22	0,40
6	43	0,78
Prosječna težina pitanja:		0,67
Standardna devijacija:		0,20

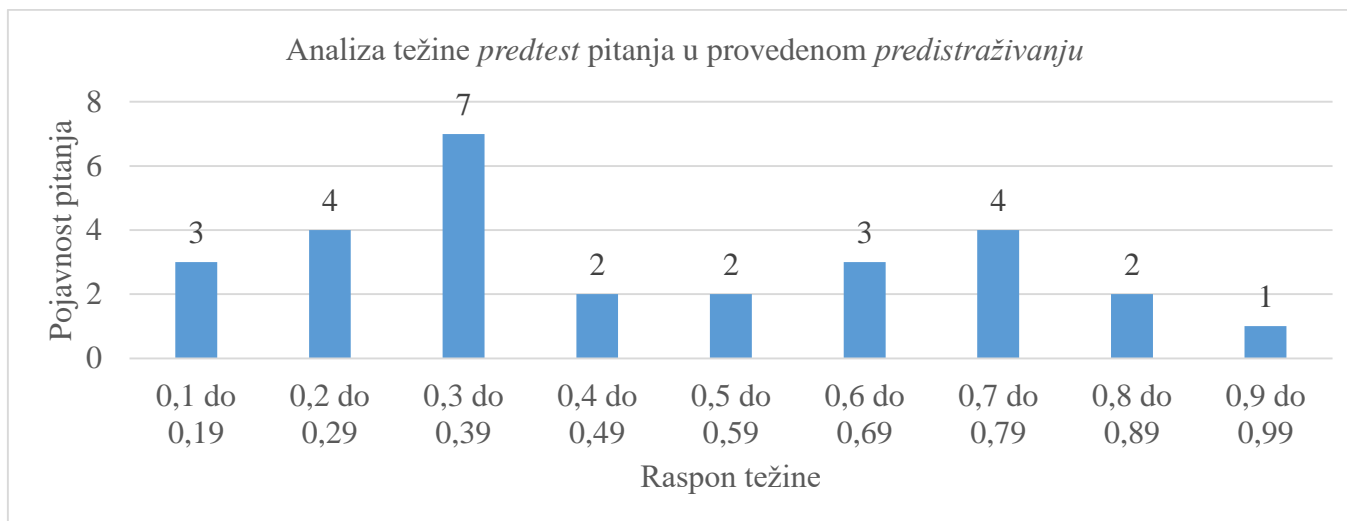
Prosječna težina pitanja **zatvorenog tipa** bila je **0,45**, dok je prosječna težina pitanja kod **otvorenog tipa** bila **0,67**. Što je vrijednost pitanja bliža 1, to je studentima pitanje bilo lakše.

U nastavku ove disertacije navodi se analiza odgovora koji su prikupljeni iz *posttest* provjere znanja koja je provedena u okviru *predistraživanja*.

Tablica 49. Analiza težine pitanja u provedenom *posttestu predistraživanja*

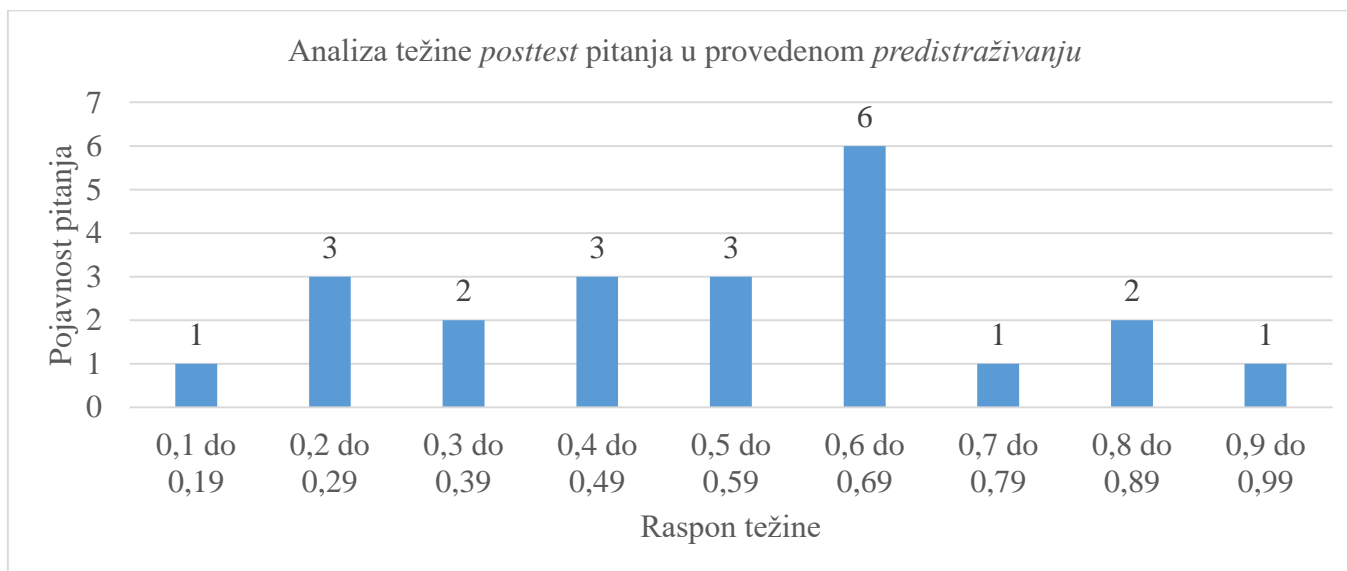
Pitanje zatvorenog tipa	Broj točnih odgovora (maks. 55 odgovora)	Težina pitanja
1	45	0,82
2	54	0,98
3	35	0,64
4	31	0,56
5	19	0,35
6	31	0,56
7	36	0,65
8	35	0,64
9	46	0,84
10	36	0,65
11	44	0,80
12	15	0,27
13	38	0,69
14	26	0,47
15	33	0,60
16	10	0,18
17	44	0,80
18	37	0,67
19	27	0,49
20	33	0,60
21	34	0,62
22	27	0,49
23	42	0,76
24	44	0,80
25	11	0,20
26	31	0,56
Prosječna težina pitanja:		0,60
Standardna devijacija:		0,20
Pitanje otvorenog tipa	Broj točnih odgovora (maks. 55 odgovora)	Težina pitanja
1	38	0,69
2	15	0,27
3	15	0,27
4	26	0,47
5	17	0,31
6	23	0,42
Prosječna težina pitanja:		0,41
Standardna devijacija:		0,16

Prosječna težina pitanja **zatvorenog tipa** bila je **0,60**, dok je prosječna težina pitanja kod **otvorenog tipa** bila **0,41**. Ukupna težina pitanja gotovo je identična između *predtest* i *posttest* provjere znanja. Bitno je napomenuti da što je vrijednost pitanja bliža 1, to je pitanje lakše.



Raspon težine	Pojavnost pitanja
0,1 do 0,19	3
0,2 do 0,29	4
0,3 do 0,39	7
0,4 do 0,49	2
0,5 do 0,59	2
0,6 do 0,69	3
0,7 do 0,79	4
0,8 do 0,89	2
0,9 do 0,99	1

Slika 39. Analiza težine pitanja iz *pretest* provjere znanja koji je korišten u *predistraživanju*



Raspon težine	Pojavnost pitanja
0,1 do 0,19	1
0,2 do 0,29	3
0,3 do 0,39	2
0,4 do 0,49	3
0,5 do 0,59	3
0,6 do 0,69	6
0,7 do 0,79	1
0,8 do 0,89	2
0,9 do 0,99	1

Slika 40. Analiza težine pitanja iz *posttest* provjere znanja koji je korišten u *predistraživanju*

6.1.3. Analiza rezultata *anketnog upitnika* u provedenom *predistraživanju*

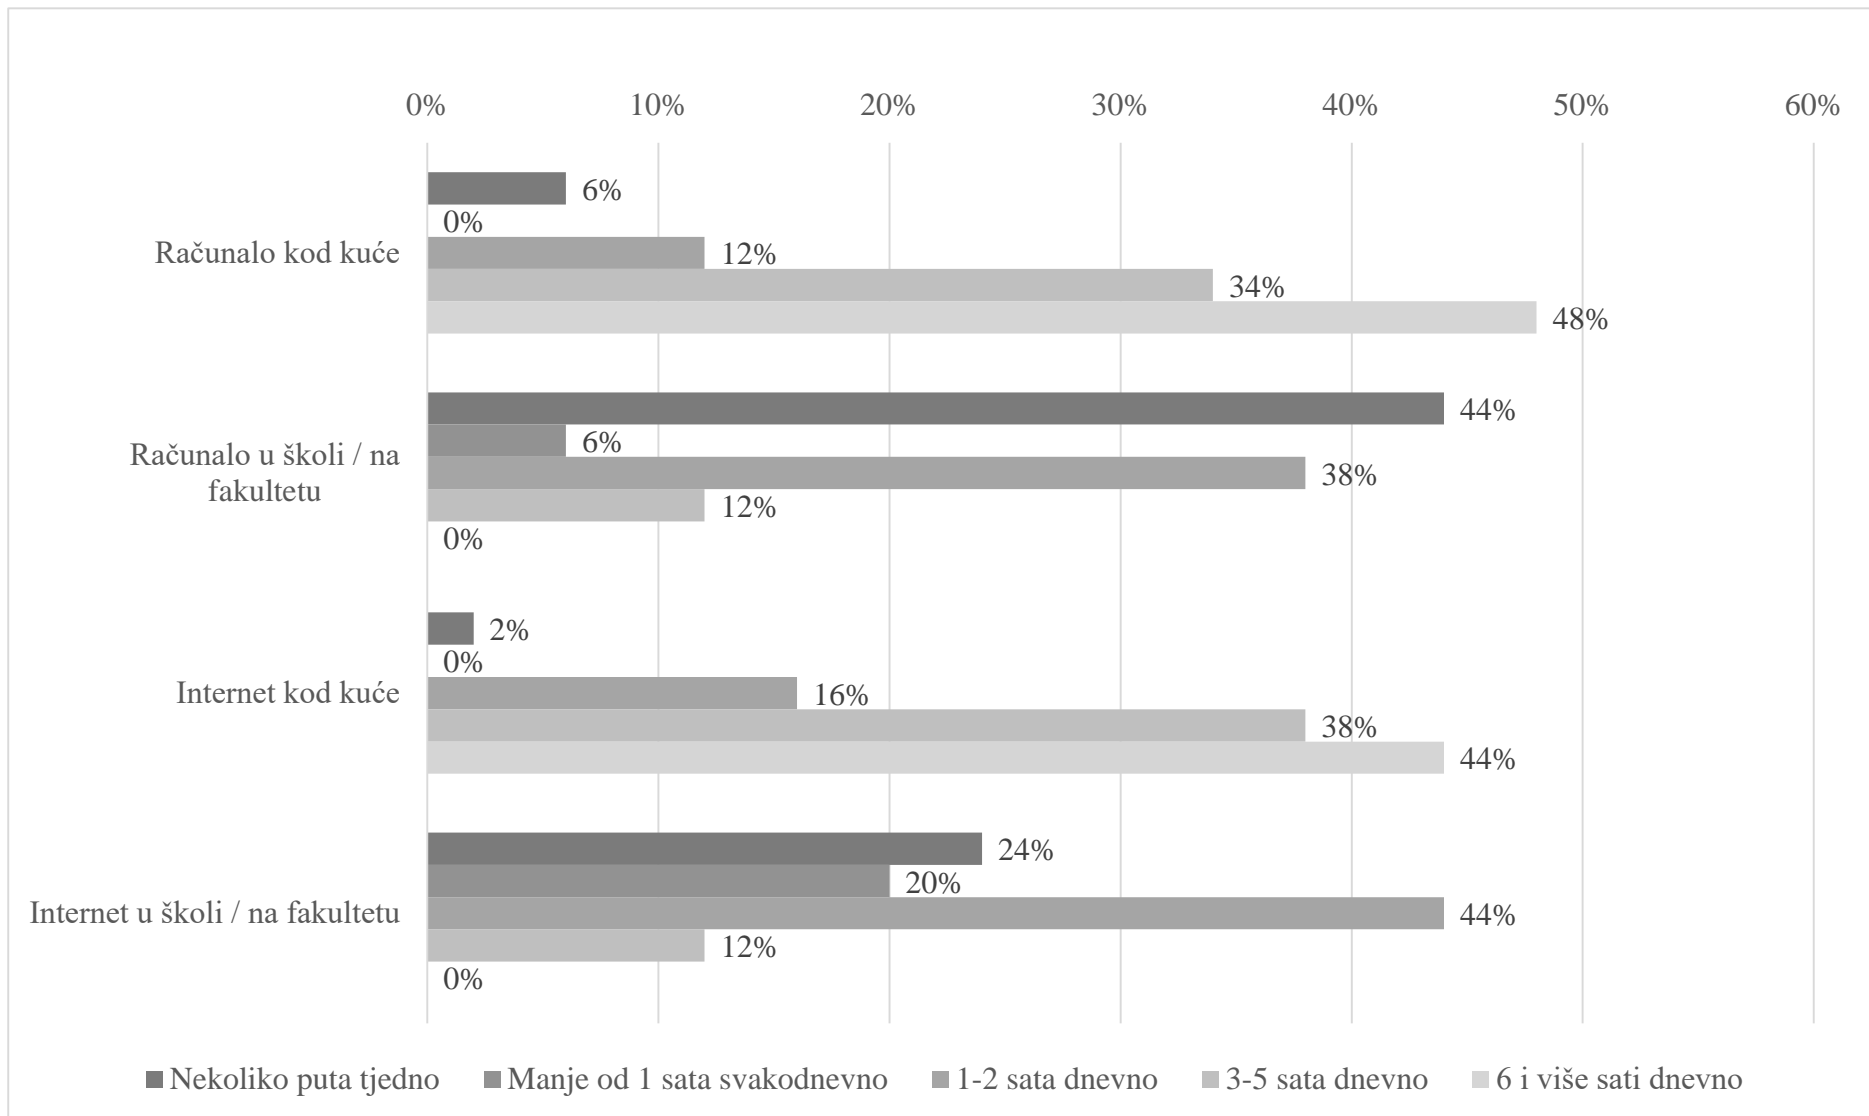
Anketni upitnik u provedenom *predistraživanju* valjano je ispunilo **50 ispitanika** od ukupno 55 polaznika e-tečaja. Rezultat dobne raspodjele ispitanika prikazan je u tablici 50. U nastavku teksta navode se deskriptivni pokazatelji za **prvu cjelinu** *anketnog upitnika* pod nazivom "*Osobni podaci*". Sve skale u potpunosti se navode u prilogu 3. i 4. ove disertacije. **Prva cjelina** *anketnog upitnika* sastoji se od **tri skale** koje se navode u nastavku rada. Cronbach alpha koeficijent za prve tri skale iznosi ,703 uz ukupan broj od 12 čestica.

Tablica 50. Analiza odgovora svih ispitanika u provedenom *predistraživanju* prema učestalosti korištenja računala i Internet tehnologije (N=50)

	Računalo kod kuće		Računalo u školi / na fakultetu		Internet kod kuće		Internet u školi / na fakultetu	
	Frekv.	%	Frekv.	%	Frekv.	%	Frekv.	%
Nekoliko puta tjedno	3	6%	22	44%	1	2%	12	24%
Manje od 1 sata svakodnevno	0	0%	3	6%	0	0%	10	20%
1-2 sata dnevno	6	12%	19	38%	8	16%	22	44%
3-5 sata dnevno	17	34%	6	12%	19	38%	6	12%
6 i više sati dnevno	24	48%	0	0%	22	44%	0	0%
Ukupno	50	100%	50	100%	50	100%	50	100%

Frekv. = frekvencija odgovora

Iz tablice 50. može se zaključiti kako ispitanici **kod kuće** koriste računalo i Internet **šest i više sati** dnevno. Ispitanici **na fakultetu** računalo koriste **nekoliko puta tjedno**, a Internet koriste **jedan do dva sata** dnevno. U nastavku rada prikazana je analiza odgovora svih ispitanika u provedenom *predistraživanju* prema učestalosti korištenja računala i Internet tehnologije.



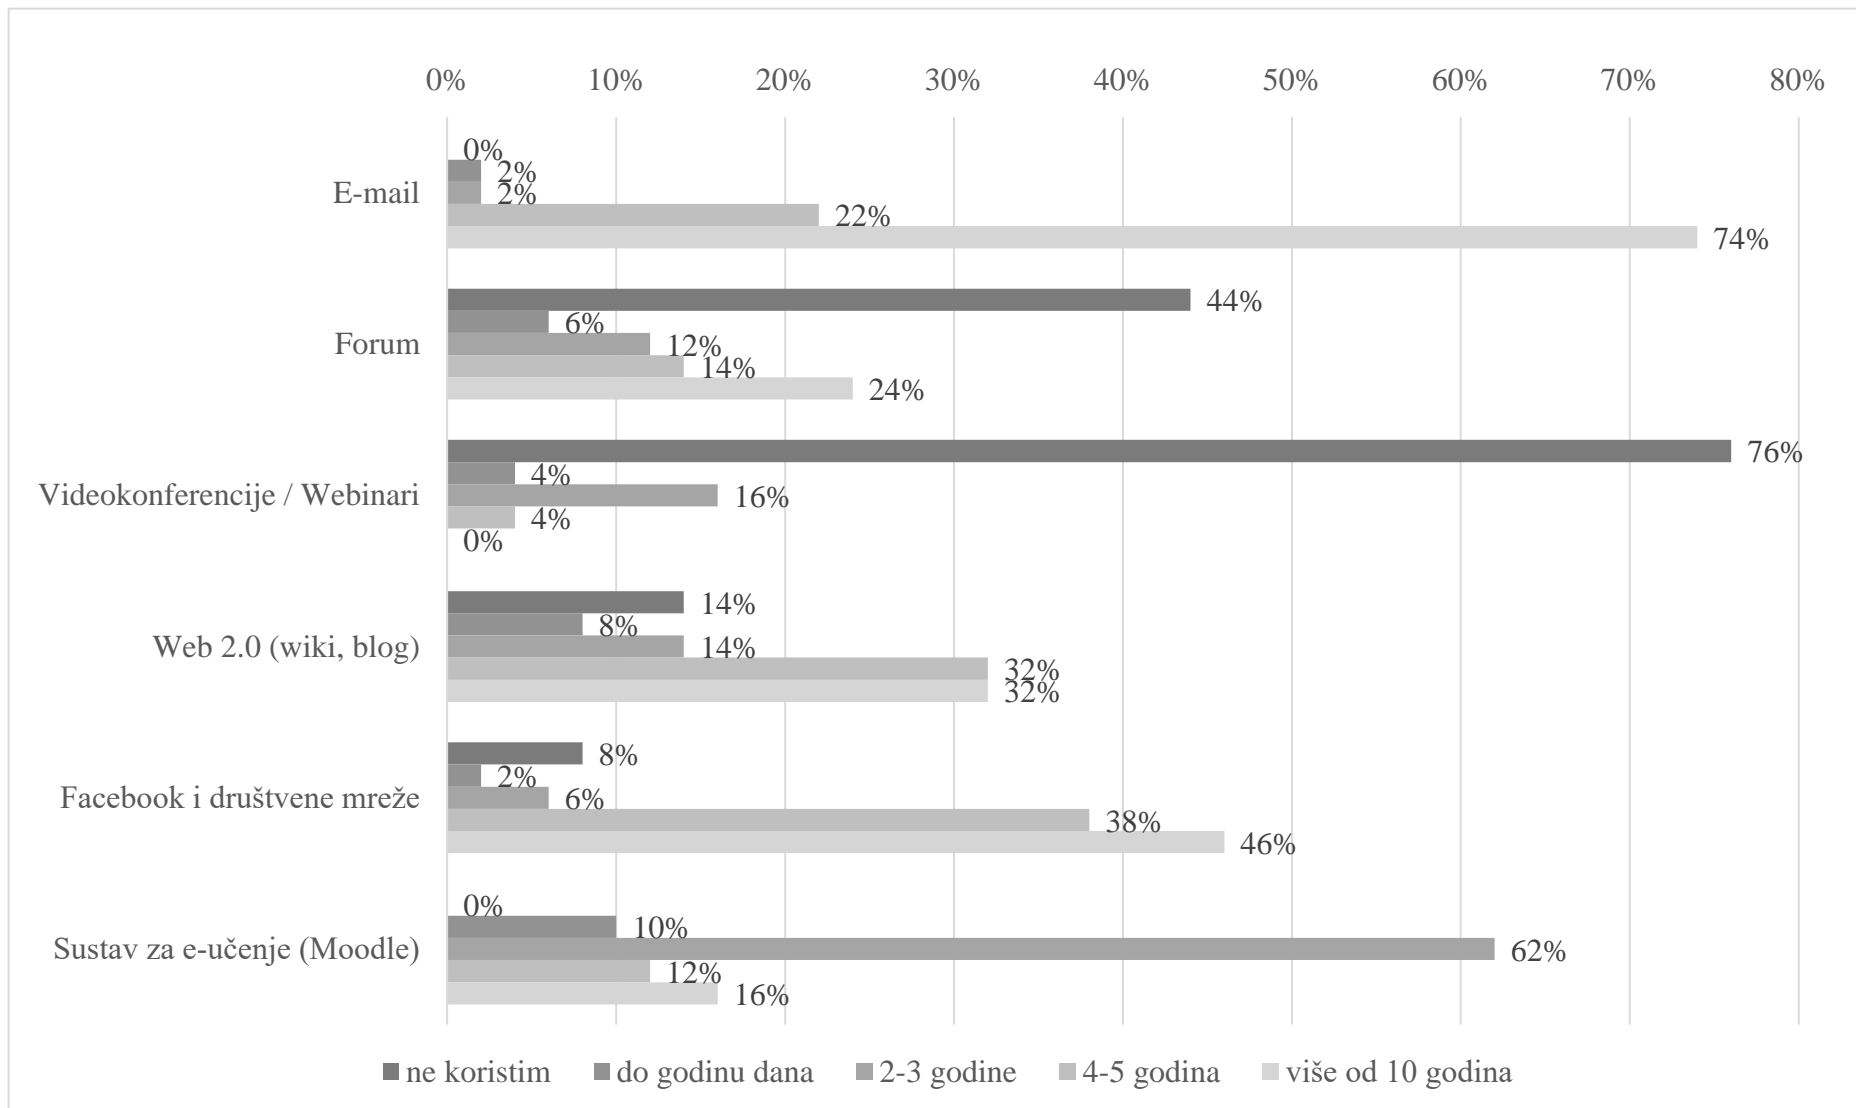
Slika 41. Grafički prikaz analize odgovora svih ispitanika u provedenom *predistraživanju* prema učestalosti korištenja računala i Internet tehnologije (N=50; uključuje *eksperimentalnu* i *kontrolnu* skupinu ispitanika)

Tablica 51. Analiza odgovora svih ispitanika u provedenom *predistraživanju* s obzirom na **dužinu korištenja** (u godinama) **Internet tehnologije** (N=50)

	E-mail		Forum		Videokonferencije / Webinar		Web 2.0 (wiki, blog)		Facebook i društvene mreže		Sustav za e-učenje (Moodle)	
	f	%	f	%	f	%	f	%	f	%	f	%
Ne koristim	0	0%	22	44%	38	76%	7	14%	4	8%	0	0%
Do godinu dana	1	2%	3	6%	2	4%	4	8%	1	2%	5	10%
2-3 godine	1	2%	6	12%	8	16%	7	14%	3	6%	31	62%
4-5 godina	11	22%	7	14%	2	4%	16	32%	19	38%	6	12%
Više od 10 godina	37	74%	12	24%	0	0%	16	32%	23	46%	8	16%
Ukupno	50	100%	50	100%	50	100%	50	100%	50	100%	50	100%

f = frekvencija odgovora

Iz tablice 51. može se zaključiti kako ispitanici *predistraživanja* koriste **e-mail** i **društvene mreže** više od 10 godina. **Forum**, **videokonferencije** i **webinar** ne koriste uopće, dok **web 2.0 alate** koriste četiri i više godina. Ispitanici koriste **sustave za e-učenje** poput Moodle-a praktički od početka studiranja, dvije do tri godine. U nastavku rada prikazana je analiza odgovora svih ispitanika u provedenom *predistraživanju* s obzirom na **dužinu korištenja** (u godinama) **Internet tehnologije**.

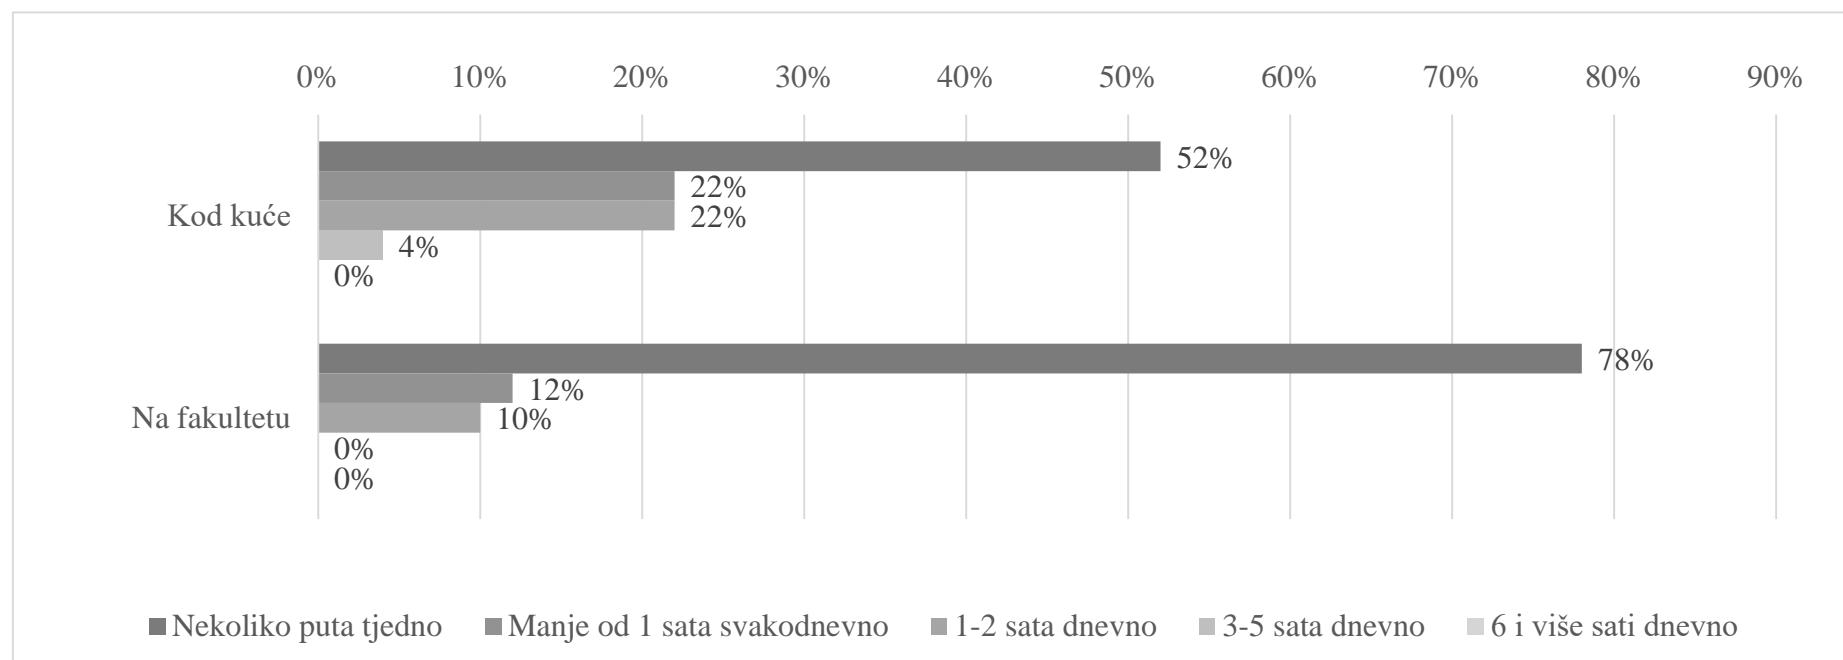


Slika 42. Grafički prikaz analize odgovora svih ispitanika u provedenom *predistraživanju* s obzirom na **dužinu korištenja** (u godinama) **Internet tehnologije** (N=50; uključuje *eksperimentalnu* i *kontrolnu* skupinu ispitanika)

Tablica 52. Analiza odgovora svih ispitanika u provedenom *predistraživanju* s obzirom na **korištenje tehnologije e-učenja** (N=50)

	Kod kuće		Na fakultetu	
	Frekv.	%	Frekv.	%
Nekoliko puta tjedno	26	52%	39	78%
Manje od 1 sata svakodnevno	11	22%	6	12%
1-2 sata dnevno	11	22%	5	10%
3-5 sata dnevno	2	4%	0	0%
6 i više sati dnevno	0	0%	0	0%
Ukupno	50	100%	50	100%

Frekv. = frekvencija odgovora



Slika 43. Grafički prikaz analize odgovora svih ispitanika u provedenom *predistraživanju* s obzirom na **korištenje tehnologije e-učenja** (N=50; uključuje *eksperimentalnu* i *kontrolnu* skupinu ispitanika)

U tablici 53. navodi se analiza rezultata za **drugu cjelinu anketnog upitnika**. Obuhvaćene su sljedeće skale: *Zadovoljstvo korištenja e-tečaja*, *Pregled nad tečajem / navigacija*, *Povratne informacije u e-tečaju*, *Zaokupljenost / uživanje*, *Priprema / uputa za rad s e-tečajem*, *Primjerena težina e-tečaja*, *Motivacijski poticaji*, *Agregacija elemenata za motivacijske poticaje*, *Interakcija unutar e-tečaja*, *Postignuće učenja*, *Individualni proces učenja*, *Doživljaj e-tečaja*, *Evaluacija e-tečaja*. Druga cjelina sastoji se od ukupno **trinaest skala** koje se navode u tablici 53. i detaljnije unutar poglavlja **Prilozi** ove doktorske disertacije.

Tablica 53. Analiza skala **druge cjeline anketnog upitnika** u provedenom **predistraživanju** prije isključivanja neodgovarajućih čestica iz skala (N=50)

Naziv skale	Broj čestica	Prosječna vrijednost	Standardna devijacija σ	Raspon odgovora	Cronbach alpha koef.
Zadovoljstvo korištenja e-tečaja	9	2,99	1,30	1-5	,892
Pregled nad tečajem / navigacija	14	3,06	1,19	1-5	,944
Povratne informacije u e-tečaju	4	3,21	1,37	1-5	,934
Zaokupljenost / uživanje	15	2,71	1,25	1-5	,852
Priprema / uputa za rad s e-tečajem	9	2,60	1,25	1-5	,925
Primjerena težina e-tečaja	8	3,17	1,39	1-5	,866
Motivacijski poticaji	5	3,02	1,26	1-5	,712
Agregacija elemenata za motivacijske poticaje	18	3,75	2,18	1-7	,957
Interakcija unutar e-tečaja	11	2,61	1,31	1-5	,903
Postignuće učenja	9	3,02	1,28	1-5	,935
Individualni proces učenja	7	3,09	1,40	1-5	,913
Doživljaj e-tečaja	11	3,18	1,40	1-5	,902
Evaluacija e-tečaja	30	2,92	1,37	1-5	,973

U tablicama 54. i 55. navode se rezultati **treće cjeline anketnog upitnika**. Obuhvaćena je skala pod nazivom *Evaluacija elemenata računalnih igara* koja se sastoji od 41 pitanja. Prvih 19 pitanja odnosi se na općenitu procjenu **mišljenja** ispitanika, dok se drugi dio od 22 pitanja odnosi na **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika.

Tablica 54. Analiza čestica **treće cjeline** *anketnog upitnika* (za čestice od 1 do 19) koja se odnosi na procjenu **mišljenja** ispitanika u provedenom *predistraživanju* (N=50)

Red. broj	Tvrdnja	Prosječna vrijednost	Standardna devijacija σ	Raspon odgovora
1	Bolje sam motiviran/a uz ljepše dizajnirano korisničko sučelje.	4,66	0,71	2-5
2	Zabavno mi je sakupljati bodove za svoja postignuća.	4,54	0,95	1-5
3	Trenutno stanje vlastitog postignuća treba biti jasno vidljivo.	4,54	0,90	1-5
4	Trenutna povratna informacija mi je poželjna.	4,64	0,77	2-5
5	Zabavno mi je otkriti sve što se, u sustavu za učenje, otkriti može.	4,48	0,78	2-5
6	Bolje pamtim kroz igru.	4,44	0,95	1-5
7	Zabavno mi je istraživati granice sustava za učenje.	3,98	1,09	1-5
8	Preferiram dinamičan sustav za učenje.	4,42	0,75	2-5
9	Preferiram jednostavno korisničko sučelje.	4,08	1,06	1-5
10	Preferiram biti vođen/a kroz sustav za učenje.	3,94	1,05	1-5
11	Stres negativno utječe na moj interes za temom.	4,46	0,83	2-5
12	Preferiram statičan oblik nastavnih sadržaja.	2,54	1,11	1-5
13	Preferiram surađivati s drugim studentima kroz timski rad.	3,42	1,17	1-5
14	Preferiram dijeliti znanje i pomagati drugima studentima.	3,92	0,89	1-5
15	Zabavno mi je natjecati se s drugim studentima.	3,32	1,31	1-5
16	Volim igrati računalne igre u slobodno vrijeme.	3,78	1,51	1-5
17	Volim igrati edukacijske računalne igre.	3,18	1,48	1-5
18	Preferiram se uspoređivati s boljim studentima.	3,00	1,38	1-5
19	Volim osjećaj svojeg napretka kroz sustav.	4,16	1,03	1-5

Tablica 55. Analiza čestica **treće cjeline anketnog upitnika** (za čestice od 20 do 41) koja se odnosi na **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika u provedenom *predistraživanju* (N=50)

Red. broj	U kolikoj mjeri smatrate da...	Prosječna vrijednost	Standardna devijacija σ	Raspon odgovora
20	... priča pomaže u boljem razumijevanju ciljeva učenja?	4,46	0,78	2-5
21	... individualni zadaci pomažu motiviranju studenata?	4,18	0,94	2-5
22	... individualni zadaci podižu interes za učenjem kod studenata?	4,00	1,01	1-5
23	... postepeno otkrivanje sadržaja pozitivno utječe na interes za temu?	4,28	0,83	2-5
24	... međusobna suradnja pozitivno utječe na Vaše učenje?	4,22	0,84	2-5
25	... natjecanje pozitivno utječe na Vaše učenje?	3,42	1,27	1-5
26	... vizualan dizajn pozitivno utječe na Vaše učenje?	4,66	0,59	3-5
27	... jednostavno grafičko sučelje pozitivno utječe na Vaše učenje?	4,22	0,86	2-5
28	... ambijent u sustavu pozitivno utječe na Vaše učenje?	4,48	0,73	3-5
29	... resursi u sustavu pozitivno utječu na Vaše učenje?	4,40	0,80	2-5
30	... pokazatelj preostalog vremena pozitivno utječe na Vaše učenje?	3,56	1,47	1-5
31	... nagrađivanje za postignuća pozitivno utječe na Vaše učenje?	4,44	0,76	2-5
32	... sakupljanje bodova pozitivno utječe na Vaše učenje?	4,46	0,81	2-5
33	... dodjela bedževa pozitivno utječe na Vaše učenje?	3,68	1,37	1-5
34	... dodjela certifikata pozitivno utječe na Vaše učenje?	4,06	1,13	1-5
35	... različite razine težine pozitivno utječe na Vaše učenje?	4,14	0,94	1-5
36	... trenutna povratna informacija pozitivno utječe na Vaše učenje?	4,48	0,73	2-5
37	... "Top 10" lista najboljih pozitivno utječe na Vaše učenje?	3,40	1,22	1-5
38	... evidencija aktivnosti pozitivno utječe na Vaše učenje?	3,94	1,13	1-5
39	... slobodan odabir materijala pozitivno utječe na Vaše učenje?	4,54	0,64	3-5
40	... raznolikost sadržaja pozitivno utječe na Vaše učenje?	4,62	0,60	3-5
41	... interaktivni materijali pozitivno utječu na Vaše učenje?	4,64	0,66	3-5

Tablica 56. Analiza rezultata *eksperimentalne* i *kontrolne* grupe u provedenom *predistraživanju* prije isključivanja neodgovarajućih čestica iz skala (N=50)

Naziv skale	Broj čestica	Cronbach alpha koef.	M _E	M _K	σ _E	σ _K	t	p
Zadovoljstvo korištenja e-tečaja	9	,892	3,187	2,758	1,306	1,267	3,50	0,0005
Pregled nad tečajem / navigacija	14	,944	3,199	2,886	1,223	1,126	3,47	0,0005
Povratne informacije u e-tečaju	4	,934	3,938	2,295	1,101	1,105	10,45	0,0001
Zaokupljenost / uživanje	15	,852	2,96	2,406	1,099	1,375	20,60	0,0001
Priprema / uputa za rad s e-tečajem	9	,925	2,873	2,263	1,224	1,214	5,26	0,0001
Primjerena težina e-tečaja	8	,866	3,196	3,148	1,484	1,270	0,34	0,7326
Motivacijski poticaji	5	,712	3,521	2,400	1,083	1,205	7,72	0,0001
Agregacija elemenata za motivacijske poticaje	18	,957	4,688	2,566	1,837	2,005	16,52	0,0001
Interakcija unutar e-tečaja	11	,903	3,149	1,926	1,129	1,220	12,16	0,0001
Postignuće učenja	9	,935	3,643	2,247	1,052	1,124	13,55	0,0001
Individualni proces učenja	7	,913	3,755	2,253	1,160	1,234	11,69	0,0001
Doživljaj e-tečaja	11	,902	3,477	2,806	1,373	1,354	5,72	0,0001
Evaluacija e-tečaja	30	,973	3,310	2,429	1,258	1,357	13,00	0,0001

M = prosječna vrijednost, σ = standardna devijacija, E = *eksperimentalna*, K = *kontrolna* grupa
t = odnos između prosječnih vrijednosti *eksperimentalne* i *kontrolne* grupe, te standardne pogreške razlike.

p = signifikantnost, tj. što je p vrijednost manja to je manja i empirijski utvrđena vjerojatnost odbacivanja istinite hipoteze i obratno. Precrtane p vrijednosti nisu statistički značajne.

6.1.4. Rasprava o rezultatima obrade podataka u *predistraživanju*

U ovom potpoglavlju prikazuju se rezultati *predistraživanja* koje se provelo nad ispitanicima Sveučilišta Sjever, koji su pohađali izborni kolegij "3D modeliranje" i dobrovoljno sudjelovali u istraživanju. Ukupno je bilo **55** ispitanika koji su prema evidenciji na vježbama podijeljeni u četiri grupe. *Eksperimentalne* grupe bile su G1 i G4, dok su *kontrolne* grupe bile G2 i G3.

6.1.4.1. *Predtest* analiza rezultata u provedenom *predistraživanju*

Predtest je test predznanja koji se koristi u svrhu osiguravanja ravnopravnosti između *kontrolnih* i *eksperimentalnih* skupina ispitanika. Na temelju ostvarenih bodova provjerava se statistička značajnost, te donosi zaključak o zadovoljavanju početnih uvjeta istraživanja.

Predtest je sadržavao ukupno 32 pitanja od kojih je 26 pitanja imalo ponuđene odgovore, dok je unutar 6 pitanja odgovor trebalo vlastoručno upisivati. Pitanja su kreirana na temelju područja 3D računalne grafike, te se navode neka kao što su pitanja o poligonima, teksturama, alatima za manipulaciju oblika i sl. Primjeri pitanja iz *predtesta* kolegija "3D modeliranje" nalaze su u prilogu 2. ove doktorske disertacije (**Slika E**)

Provedeno je testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta* *eksperimentalne* (G1) grupe (N=15) i *kontrolne* (G2) grupe (N=13), gdje se može zaključiti kako između grupa **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*. Ista provjera provedena je i nad drugom skupinom ispitanika, gdje se razlikuje *eksperimentalna* (G4) grupa (N=13) i *kontrolna* (G3) grupa (N=14). Prema tablici 38. koja prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja, može se zaključiti kako između navedenih ispitanika *eksperimentalne* (G4) i *kontrolne* (G3) grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*. Posljednja provjera je provedena nad svim ispitanicima *eksperimentalne* (G1, G4) grupe, te nad svim ispitanicima *kontrolne* (G2, G3) grupe. Iz tablice 39., koja je prikazana unutar poglavlja 6.1.1., može se zaključiti kako između svih ispitanika *eksperimentalne* (G1, G4) grupe te svih ispitanika *kontrolne* (G2, G3) grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*.

Na temelju rezultata *predtesta* zaključuje se kako se grupe statistički značajno ne razlikuju, te se ukazuje na mogućnost kojom se kroz provedbu *eksperimenta* može doći do statistički značajnih rezultata. *Eksperimentalna* grupa izložena je gemificiranom e-tečaju, dok je *kontrolna* izložena klasičnom e-tečaju u kojima se nastavni sadržaji međusobno ne razlikuju.

6.1.4.2. *Posttest analiza rezultata u provedenom predistraživanju*

Posttest provjera je test stečenog znanja koji se koristio u svrhu provjere znanja nakon korištenja *eksperimentalnog* sustava. Sustav je bio aktivan minimalno dva tjedna tijekom kojih su studenti imali pristup nastavnim i nenastavnim materijalima. Rezultati *posttesta* korišteni su za utvrđivanje statistički značajne razlike između navedenih skupina ispitanika. *Eksperimentalne* i *kontrolne* grupe nisu mijenjane s obzirom na dokazanu ravnopravnost između grupa koja je prikazana u testiranju **statističkih značajnosti razlika** u poglavlju 6.1.1.

Posttest je sadržavao 32 pitanja. Struktura pitanja ista je kao i u provedenom *predtestu*. Pitanja su obuhvaćala specifične pojmove koji su se nalazili unutar *gemificiranog* e-tečaja. Nastavna cjelina je uključivala sadržaje 3D računalnog osvjetljenja i renderiranja. Provjera znanja temeljena je na pitanjima o ambijentalnom osvjetljenju, mapama fotona, zamućenosti pogleda, praćenju zraka svjetlosti i sl. U *posttest* provjeri mjerena je usvojenost znanja polaznika s obzirom na nastavne sadržaje *gemificiranog* i *klasičnog* e-tečaja. Primjer pitanja iz *posttesta* kolegija "3D modeliranje" nalazi se u prilogu 2. ovog rada (**Slika F**).

Provedeno je testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta* *eksperimentalne* (**G1**) grupe (N=15) i *kontrolne* (**G2**) grupe (N=13), uz izračun **p vrijednosti** koja je iznosila **0,005**. Iz navedenog se može zaključiti, uz mogućnost pogreške od 1%, kako između prve *eksperimentalne* (**G1**) i prve *kontrolne* (**G2**) grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*. Testiranje **statističke značajnosti razlike** metodom t-testa provedeno je između rezultata *posttesta* *eksperimentalne* (**G4**) grupe (N=13) i *kontrolne* (**G3**) grupe (N=14). Izračunata **p vrijednost** iznosila je **0,01**, prema kojoj se može zaključiti, uz mogućnost pogreške od 5%, kako između navedenih ispitanika *eksperimentalne* (**G4**) i *kontrolne* (**G3**) grupe **postoji statistički značajna razlika**.

Posljednja provjera provedena je nad svim ispitanicima *eksperimentalne* (**G1, G4**) grupe te nad svim ispitanicima *kontrolne* (**G2, G3**) grupe. Iz tablice 42., koja je prikazana unutar poglavlja 6.1.2. i izračunate **p vrijednosti** koja je iznosila **0,0002**, može se zaključiti kako između svih ispitanika *eksperimentalne* (**G1, G4**) grupe te svih ispitanika *kontrolne* (**G2, G3**) grupe, uz mogućnost pogreške od 1%, **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*. *Eksperimentalna* grupa ostvarila je **bolji rezultat** za **36,55%**

6.1.4.3. Unutarnja konzistentnost skala u provedenom *predistraživanju*

Treći instrument koji je korišten unutar ove doktorske disertacije je *anketni upitnik* kojim se prikupljaju mišljenja studenata o *eksperimentalnom* e-tečaju, motivacijskim elementima računalnih igara, sustavima poticanja i nagrađivanja i dr.

Anketni upitnici kreirani su jednim dijelom na temelju stručne i znanstvene literature. U tu svrhu korišteno je 14 istraživačkih radova za kreiranje novih mjernih skala, dok je ostatak upitnika autorski uradak uz pomoć i savjetovanje mentora ove disertacije.

- **Prvi dio** *anketnog upitnika* broji 19 čestica te je evidentiran unutar naziva *Osobni podaci*.
- **Drugi dio** *anketnog upitnika* sadrži ukupno 150 čestica koje su podijeljene u 13 mjernih skala pod sljedećim nazivima: *Zadovoljstvo korištenja e-tečaja, Pregled nad tečajem / navigacija, Povratne informacije u e-tečaju, Zaokupljenost / uživljavanje, Priprema / uputa za rad s e-tečajem, Primjerena težina e-tečaja, Motivacijski poticaji, Agregacija elemenata za motivacijske poticaje, Interakcija unutar e-tečaja, Postignuće učenja, Individualni proces učenja, Doživljaj e-tečaja, Evaluacija e-tečaja*.
- **Treći dio** *anketnog upitnika* evidentiran je pod nazivom *Evaluacija elemenata računalnih igara* koji se sastoji od 41 čestice. Prvih 19 pitanja odnosi se na općenitu procjenu **mišljenja** ispitanika, dok se drugi dio od 22 pitanja odnosi na **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika.

Tablica 57. Pregled isključenih čestica iz skala i daljnje obrade u provedenom *predistraživanju*

Naziv skale	Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach alpha ako se čestica izbac
Pregled nad tečajem / navigacija	NAV_6	,559	,944
	NAV_10R	,534	,945
	NAV_11	,562	,944
Zaokupljenost / uživljavanje	UZI_8	-,096	,875
	UZI_11R	-,255	,883
Priprema / uputa za rad s e-tečajem	UPT_1	,525	,930
	UPT_4R	,585	,926
Motivacijski poticaji	POT_2R	-,014	,842
Interakcija unutar e-tečaja	INT_10	,170	,918
Doživljaj e-tečaja	DOZ_4R	,060	,922
Evaluacija e-tečaja	EVA_16R	,101	,976
	EVA_26R	,677	,973

Nakon isključivanja neodgovarajućih čestica iz skala i daljnje obrade, *anketni upitnik* u drugom dijelu broji **138 čestica**. Prvi i treći dio su nepromijenjeni. Kompletna analiza je u **prilogu 5**.

Tablica 58. Usporedni prikaz analize anketnog upitnika prije i nakon isključivanja neodgovarajućih čestica iz skala (N=50)

Naziv skale	Analiza anketnog upitnika <u>prije</u> isključivanja neodgovarajućih čestica iz skala (N=50)				Analiza anketnog upitnika <u>nakon</u> isključivanja neodgovarajućih čestica iz skala (N=50)			
	Broj čestica	Prosječna vrijednost	Standardna devijacija σ	Cronbach alpha koef.	Broj čestica	Prosječna vrijednost	Standardna devijacija σ	Cronbach alpha koef.
Zadovoljstvo korištenja e-tečaja	9	2,99	1,30	,892	9	2,99	1,30	,892
Pregled nad tečajem / navigacija	14	3,06	1,19	,944	11	3,05	1,21	,946
Povratne informacije u e-tečaju	4	3,21	1,37	,934	4	3,21	1,37	,934
Zaokupljenost / uživanje	15	2,71	1,25	,852	13	2,76	1,24	,907
Priprema / uputa za rad s e-tečajem	9	2,60	1,25	,925	7	2,60	1,24	,932
Primjerena težina e-tečaja	8	3,17	1,39	,866	8	3,17	1,39	,866
Motivacijski poticaji	5	3,02	1,26	,712	4	3,09	1,25	,842
Agregacija elemenata za motivacijske poticaje	18	3,75	2,18	,957	18	3,75	2,18	,957
Interakcija unutar e-tečaja	11	2,61	1,31	,903	10	2,52	1,29	,918
Postignuće učenja	9	3,02	1,28	,935	9	3,02	1,28	,935
Individualni proces učenja	7	3,09	1,40	,913	7	3,09	1,40	,913
Doživljaj e-tečaja	11	3,18	1,40	,902	10	3,23	1,40	,922
Evaluacija e-tečaja	30	2,92	1,37	,973	28	2,92	1,36	,976

6.1.4.4. Razlika *eksperimentalne* i *kontrolne* skupine u odnosu na rezultate primjenom skala za procjenu

Tablica 59. Analiza rezultata *eksperimentalne* i *kontrolne* grupe u provedenom *predistraživanju* nakon korekcije svih skala (N=50)

Naziv skale	Broj čestica	Cronbach alpha koef.	M _E	M _K	σ _E	σ _K	t	p
Zadovoljstvo korištenja e-tečaja	9	,892	3,18	2,75	1,30	1,26	3,50	0,0005
Pregled nad tečajem / navigacija	11	,946	3,21	2,85	1,25	1,13	3,54	0,0004
Povratne informacije u e-tečaju	4	,934	3,93	2,29	1,10	1,10	10,45	0,0001
Zakupljenost / uživanje	13	,907	3,03	2,42	1,07	1,36	6,35	0,0001
Priprema / uputa za rad s e-tečajem	7	,932	2,92	2,19	1,21	1,17	5,70	0,0001
Primjerena težina e-tečaja	8	,866	3,19	3,14	1,48	1,27	0,34	0,7326
Motivacijski poticaji	4	,842	3,68	2,34	0,96	1,16	10,44	0,0001
Agregacija elemenata za motivacijske poticaje	18	,957	4,68	2,56	1,83	2,00	16,52	0,0001
Interakcija unutar e-tečaja	10	,918	3,08	1,80	1,12	1,14	12,54	0,0001
Postignuće učenja	9	,935	3,64	2,24	1,05	1,12	13,55	0,0001
Individualni proces učenja	7	,913	3,75	2,25	1,16	1,23	11,69	0,0001
Doživljaj e-tečaja	10	,922	3,56	2,81	1,34	1,37	6,11	0,0001
Evaluacija e-tečaja	28	,976	3,38	2,35	1,24	1,30	15,04	0,0001

M = prosječna vrijednost, σ = standardna devijacija, E = *eksperimentalna*, K = *kontrolna* grupa
p = signifikantnost, precrtane p vrijednosti nisu statistički značajne.

Iz tablice 59. vidljivo je kako jedino u skali *Primjerena težina e-tečaja* ne postoji statistički značajna razlika između *eksperimentalne* i *kontrolne* grupe ispitanika. Skupni odgovori u svim ostalim slučajevima se statistički značajno razlikuju, što je bilo i očekivano s obzirom kako *kontrolna* grupa nije sudjelovala u gemificiranom e-tečaju. Sadržaji oba e-tečaja su identični.

Tablica 60. Analiza čestica **treće cjeline** anketnog upitnika (za čestice od 1 do 19) koja se odnosi na procjenu **mišljenja** ispitanika u provedenom **predistraživanju** (N=50)

Red. broj	Tvrdnja	M_E	M_K	σ_E	σ_K	t	p
1	Bolje sam motiviran/a uz ljepše dizajnirano korisničko sučelje.	4,64	4,68	0,78	0,65	0,18	0,8511
2	Zabavno mi je sakupljati bodove za svoja postignuća.	4,64	4,41	0,73	1,18	0,85	0,3943
3	Trenutno stanje vlastitog postignuća treba biti jasno vidljivo.	4,36	4,77	1,10	0,53	1,63	0,1090
4	Trenutna povratna informacija mi je poželjna.	4,68	4,59	0,72	0,85	0,39	0,6961
5	Zabavno mi je otkriti sve što se, u sustavu za učenje, otkriti može.	4,54	4,41	0,69	0,91	0,55	0,5784
6	Bolje pamtim kroz igru.	4,36	4,55	1,03	0,86	0,69	0,4927
7	Zabavno mi je istraživati granice sustava za učenje.	4,07	3,86	1,05	1,17	0,66	0,5118
8	Preferiram dinamičan sustav za učenje.	4,46	4,36	0,69	0,85	0,46	0,6461
9	Preferiram jednostavno korisničko sučelje.	4,00	4,18	1,02	1,14	0,59	0,5548
10	Preferiram biti vođen/a kroz sustav za učenje.	3,79	4,14	1,13	0,94	1,16	0,2486
11	Stres negativno utječe na moj interes za temom.	4,29	4,68	0,81	0,84	1,69	0,0975
12	Preferiram statičan oblik nastavnih sadržaja.	2,68	2,36	1,12	1,09	0,99	0,3245
13	Preferiram surađivati s drugim studentima kroz timski rad.	3,57	3,23	1,14	1,23	1,02	0,3107
14	Preferiram dijeliti znanje i pomagati drugima studentima.	3,89	3,95	0,92	0,90	0,23	0,8127
15	Zabavno mi je natjecati se s drugim studentima.	3,71	2,82	1,21	1,30	2,51	0,0153
16	Volim igrati računalne igre u slobodno vrijeme.	3,71	3,86	1,54	1,52	0,34	0,7333
17	Volim igrati edukacijske računalne igre.	3,07	3,32	1,59	1,36	0,58	0,5639
18	Preferiram se uspoređivati s boljim studentima.	3,43	2,45	1,40	1,18	2,61	0,0120
19	Volim osjećaj svojeg napretka kroz sustav.	4,21	4,09	0,92	1,19	0,41	0,6808

M = prosječna vrijednost, σ = standardna devijacija, E = eksperimentalna, K = kontrolna grupa

p = signifikantnost, precrtane p vrijednosti nisu statistički značajne.

Tablica 61. Analiza čestica treće cjeline anketnog upitnika (za čestice od 20 do 41) koja se odnosi na **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika u provedenom **predistraživanju** (N=50)

Red. broj	U kolikoj mjeri smatrate da...	M_E	M_K	σ_E	σ_K	t	p
20	... priča pomaže u boljem razumijevanju ciljeva učenja?	4,43	4,50	0,79	0,80	0,31	0,7539
21	... individualni zadaci pomažu motiviranju studenata?	4,18	4,18	1,02	0,85	0,01	0,9905
22	... individualni zadaci podižu interes za učenjem kod studenata?	4,04	3,95	0,88	1,17	0,27	0,7812
23	... postepeno otkrivanje sadržaja pozitivno utječe na interes za temu?	4,25	4,32	0,89	0,78	0,28	0,7774
24	... međusobna suradnja pozitivno utječe na Vaše učenje?	4,07	4,41	0,94	0,67	1,42	0,1605
25	... natjecanje pozitivno utječe na Vaše učenje?	3,71	3,05	1,21	1,29	1,88	0,0659
26	... vizualan dizajn pozitivno utječe na Vaše učenje?	4,57	4,77	0,69	0,43	1,19	0,2371
27	... jednostavno grafičko sučelje pozitivno utječe na Vaše učenje?	4,11	4,36	0,92	0,79	1,04	0,3022
28	... ambijent u sustavu pozitivno utječe na Vaše učenje?	4,50	4,45	0,75	0,74	0,21	0,8307
29	... resursi u sustavu pozitivno utječu na Vaše učenje?	4,29	4,55	0,85	0,74	1,13	0,2635
30	... pokazatelj preostalog vremena pozitivno utječe na Vaše učenje?	3,71	3,36	1,33	1,65	0,83	0,4090
31	... nagrađivanje za postignuća pozitivno utječe na Vaše učenje?	4,39	4,50	0,88	0,60	0,49	0,6258
32	... sakupljanje bodova pozitivno utječe na Vaše učenje?	4,36	4,59	0,91	0,67	1,00	0,3181
33	... dodjela bedževa pozitivno utječe na Vaše učenje?	3,86	3,45	1,24	1,53	1,02	0,3096
34	... dodjela certifikata pozitivno utječe na Vaše učenje?	4,14	3,95	1,04	1,25	0,57	0,5648
35	... različite razine težine pozitivno utječe na Vaše učenje?	4,18	4,09	0,90	1,02	0,32	0,7491
36	... trenutna povratna informacija pozitivno utječe na Vaše učenje?	4,32	4,68	0,86	0,48	1,75	0,0853
37	... "Top 10" lista najboljih pozitivno utječe na Vaše učenje?	3,61	3,14	1,07	1,39	1,35	0,1814
38	... evidencija aktivnosti pozitivno utječe na Vaše učenje?	4,04	3,82	1,04	1,26	0,67	0,5057
39	... slobodan odabir materijala pozitivno utječe na Vaše učenje?	4,50	4,59	0,69	0,59	0,49	0,6261
40	... raznolikost sadržaja pozitivno utječe na Vaše učenje?	4,57	4,68	0,69	0,48	0,63	0,5256
41	... interaktivni materijali pozitivno utječu na Vaše učenje?	4,68	4,59	0,67	0,67	0,46	0,6472

p = signifikantnost, precrtane p vrijednosti nisu statistički značajne.

Iz priloženih tablica 60. i 61., koje analiziraju skalu **trećeg dijela anketnog upitnika** koji se odnosi na procjenu **mišljenja** ispitanika i **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika u provedenom **predistraživanju** (N=50), može se zaključiti kako obje grupe (*eksperimentalna* i *kontrolna*) imaju podjednake odgovore. Od ukupno 41 pitanja ili tvrdnje samo se dvije tvrdnje: "**Zabavno mi je natjecati se s drugim studentima.**" i "**Preferiram se uspoređivati s boljim studentima.**" statistički razlikuju između grupa.

Tablica 62. Testiranje **statističke značajnosti razlike** metodom t-testa između prosječnih rezultata odgovora na sve čestice **treće cjeline anketnog upitnika** (N=50)

Ispitanici	Broj ispitanika	Broj čestica	Prosječna vrijednost odgovora M	Standardna devijacija σ	t	p
G_E	28	41	4,11	0,44	0,38	0,7013
G_K	22	41	4,06	0,64		

G_E = *eksperimentalna* grupa, **G_K** = *kontrolna* grupa

Tablica 62. prikazuje izračun statističke značajnosti na temelju prosječnih rezultata odgovora na čestice **treće cjeline anketnog upitnika** (za čestice od 1 do 41), prema kojoj se može zaključiti kako između *eksperimentalne* (**G_E**) i *kontrolne* (**G_K**) grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate upitnika. Eksperiment nije utjecao na mišljenje ispitanika *eksperimentalne* grupe. Prosječna vrijednost odgovora obje grupe prelazi vrijednost 4 od maksimalne vrijednosti 5, prema kojoj se može zaključiti kako ispitanici imaju **pozitivan stav** o **motivacijskim elementima** iz računalnih igara.

6.1.4.5. Zaključci imajući u vidu hipoteze i rezultate *predistraživanja*

Prva hipoteza ove disertacije glasi:

H1. E-tečaj dizajniran uz primjenu elemenata računalnih igara **pozitivno utječe na zainteresiranost** polaznika tog tečaja u odnosu na tečaj istog obrazovnog sadržaja, ali bez prisutnosti elemenata računalnih igara.

Kako bi se potvrdila hipoteza H1, provedeno je istraživanje literature gdje su evidentirani brojni radovi koji upućuju na pozitivne efekte i pomake u vidu motivacije polaznika. U trenutku provođenja istraživanja, autor ove disertacije nije pronašao niti jedan rad sa smjernicama kako implementirati gemifikacijske elemente unutar Moodle sustava, niti koji su dodaci najbolji za potrebe obrazovnog sustava visokog školstva. Na raspolaganju je jedino službeni forum Moodle.org-a koji nije redovito ažuriran po pitanju elemenata računalnih igara u obrazovnom sustavu.

Iz navedenih razloga pokrenuta je izrada novog *gemificiranog* sustava koji se temelji na Moodle 2.7 platformi prema sljedećim koracima.

1. korak: identificiranje svih dostupnih Moodle dodataka koji su pogodni za visokoškolsko obrazovanje i za implementaciju u 2.7 verziju sustava.
2. korak: izrada **konceptualnog gemificiranog eRIOOS modela** temeljem kojeg je moguće razviti cjelokupan e-tečaj namijenjen za visokoškolsko obrazovanje.
3. korak: **implementacija sustava** gdje se paralelno razvija *gemificirani* i *klasični* e-tečaj na dva odvojena poslužitelja (eng. *server*).
4. korak: **provođenje eksperimenta** u vremenskom razdoblju od **21 do 25 dana**.
5. korak: **usporediti** objektivne **pokazatelje** aktivnosti polaznika unutar oba e-tečaja i **dopuniti zaključke** o utjecaju na zainteresiranost polaznika.

Tvrđnja hipoteze H1 je potvrđena. Odluka se temelji na odgovorima iz *anketnog upitnika* i temeljem objektivnih pokazatelja studentskih aktivnosti unutar Moodle e-tečaja.

Predistraživanje je provedeno nad 50 ispitanika koji su koristili e-tečaj temeljen na eRIOOS modelu. *Eksperimentalna* grupa broji 28, dok *kontrolna grupa* 22 ispitanika. Nakon dva tjedna korištenja e-tečaja, studenti su pristupili *anketnom upitniku* motivacije i zadovoljstva koji je povezan s **hipotezom H1**. *Anketni upitnik* sastoji se od tri dijela, gdje se prvi dio odnosi na deskriptivne pokazatelje, drugi dio na zadovoljstvo, motivaciju, interakciju i proces učenja, a treći dio na zainteresiranost i **utjecaj motivacijskih elemenata** iz računalnih igara na učenje.

Drugi dio *anketnog upitnika*, nakon izbacivanja neodgovarajućih čestica, broji 138 čestica koje su podijeljene u 13 skala. Iz analize skala u **potpoglavlju 6.1.4.4.** može se zaključiti kako *eksperimentalna* grupa u odnosu na *kontrolnu* grupu ispitanika ima veće prosječne vrijednosti odgovora u svakoj skali više. Statistički značajna razlika evidentirana je u svakoj skali osim kod skale **Primjerena težina e-tečaja**. Ako se pogledaju ukupni pokazatelji, koji su navedeni u tablici 63., vidljivo je kako je i u tom slučaju evidentirana izrazita statistički značajna razlika.

Tablica 63. Testiranje **statističke značajnosti razlike** metodom t-testa između prosječnih rezultata odgovora **druge cjeline** nakon korekcije *anketnog upitnika* (N=50)

Ispitanici	Broj ispitanika	Broj skala	Prosječna vrijednost odgovora M	Standardna devijacija σ	t	p
G_E	28	13	3,48	0,47	6,20	0,0001
G_K	22	13	2,46	0,35		

G_E = *eksperimentalna* grupa, **G_K** = *kontrolna* grupa

Tablica 63. prikazuje izračun statističke značajnosti na temelju prosječnih rezultata odgovora **druge cjeline anketnog upitnika**. Druga cjelina broji 13 skala čije su prosječne vrijednosti temeljene na 138 čestica. Izračunata p vrijednost navodi mogući zaključak, uz mogućnost pogreške od 1%, kako između *eksperimentalne* (ГЕ) i *kontrolne* (ГК) grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate odgovora svih skala koje se nalaze unutar drugog dijela *anketnog upitnika*. Testiranje je provedeno na uzorku od 50 ispitanika.

Treći dio *anketnog upitnika* sastoji se od jedne skale koja broji 41 česticu. *Anketni upitnik* evidentira **mišljenja** ispitanika i **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika. U *anketnom upitniku*, gdje je raspon mogućih odgovora od 1-5, vidljivo je kako je prosječna vrijednost odgovora za *eksperimentalnu* grupu iznosila 4,11, dok je za *kontrolnu* grupu iznosila 4,06. Temeljem navedenog se može zaključiti kako ispitanici imaju pozitivan stav o **motivacijskim elementima** iz računalnih igara. Između grupa **ne postoji statistički značajna razlika**, što znači kako eksperiment nije utjecao na mišljenje polaznika o motivirajućim elementima. Pretpostavka jest kako **kontrolna grupa nije** vidjela *eksperimentalni* e-tečaj, niti je **sudjelovala** u istom, no ipak ima **pozitivno mišljenje** o elementima računalnih igara u obrazovnom sustavu, što ide u prilog zaključku disertacije.

U nastavku disertacije navode se izvještaji o studentskim aktivnostima koji su generirani na temelju *log* zapisa iz Moodle sustava, te ujedno predstavljaju i završni dio koji se uzima u obzir prilikom donošenja zaključka o prihvaćanju ili odbacivanju **hipoteze H1** i **podhipoteze H1.1**.

Tablica 64. navodi popis aktivnosti koje su namijenjene **predistraživanju** ove disertacije. Prazan prostor koji je vidljiv unutar *kontrolne* grupe, ukazuje na to kako ispitanici koji su koristili *kontrolni* e-tečaj nisu mogli pristupiti navedenim aktivnostima. Razlog tome je taj što su navedene aktivnosti vezane uz osnovne principe računalnih igara koji su objašnjeni unutar teorijskog dijela ove disertacije u poglavlju 4.2.

Tablica 64. Izvještaj o aktivnosti *eksperimentalne* (N=26) i *kontrolne* grupe (N=24) polaznika

Naziv aktivnosti (obrazovna tema)	Aktivnost <i>eksperimentalne</i> grupe			Aktivnost <i>kontrolne</i> grupe		
	Ukupno	Prosjeak	SD	Ukupno	Prosjeak	SD
Check lista	154	5,92	7,98			
Dobrodošli u sustav 3DM	434	16,69	70,23	6	0,25	0,53
Ishodi učenja kolegija 3DM	188	7,23	27,34	11	0,46	0,72
Video - <i>Maya Learning Channel</i>	99	3,81	10,35	3	0,13	0,34
Poglavlje - Uvod u Mayu 2014	86	3,31	6,56	0	0,00	0,00
Ishodi učenja	780	30,00	106,53	13	0,54	0,83
Forum	611	23,50	89,14	8	0,33	0,56
Nastavno poglavlje: Mental ray 1	146	5,62	8,00	3	0,13	0,45
Nastavno poglavlje: Osnove osvjetljenja	582	22,38	83,30	9	0,38	0,82
Nastavno poglavlje: Indirektno osvjetljenje 1	556	21,38	83,10	5	0,21	0,41
Nastavno poglavlje: Indirektno osvjetljenje 2	491	18,88	72,79	3	0,13	0,34
Izazov: Osvjetljenje	521	20,04	70,70			
Bonus nastavni sadržaj: Život poslije PI	496	19,08	70,36	3	0,13	0,34
Nastavno poglavlje: Osvjetljenje i renderiranje	465	17,88	64,19	9	0,38	0,65
Nastavno poglavlje: Mental Ray 2	442	17,00	62,52	11	0,46	0,88
Nastavno poglavlje: Maya i Keyshot	425	16,35	61,13	2	0,08	0,28
Izazov: Renderiranje	440	16,92	59,17			
Bonus nastavni sadržaj: <i>IBL</i>	422	16,23	56,69	4	0,17	0,48
Bonus nastavni sadržaj: Renderiranje u slojevima	406	15,62	55,98	9	0,38	0,65
Aktivnosti polaznika e-tečaja (Suma, Prosjeak)	7744	15,68		99	0,26	

Aktivnost polaznika, koja se prikazuje u zadnjem retku tablice, pokazuje ukupan broj pristupa materijalima e-tečaja, te za *eksperimentalnu* grupu iznosi **7744**, dok za *kontrolnu* grupu iznosi **99**. Studenti *eksperimentalne* grupe su nastavnim i nenastavnim materijalima prosječno pristupali **15,68** puta, dok su studenti *kontrolne* grupe nastavnim i nenastavnim materijalima prosječno pristupali **0,26** puta.

Vidljivo je kako je *eksperimentalna* grupa ispitanika pokazala znatno veći interes za općenitim elementima sustava kao što su cjeline pod nazivima "*Dobrodošli u sustav 3DM*" i "*Ishodi učenja*". U slučaju *predistraživanja* bonus nastavni materijali bili su uključeni u oba e-tečaja. Zanimljivo je kako je visok interes *eksperimentalne* grupe ispitanika za nastavnim i bonus materijalima gotovo konstantan, isto kao i vrlo nizak interes kod *kontrolne* grupe ispitanika.

Iz navedenih pokazatelja može se zaključiti kako je *eksperimentalna* grupa ispitanika imala znatno veću motiviranost, što je vidljivo kroz veću evidentiranu aktivnost unutar Moodle e-tečaja s obzirom na korištenje dostupnih **nastavnih i nenastavnih materijala**, čime se **prihvća tvrdnja hipoteze H1**.

Pretpostavke autora (poput Chou, 2016.; Lombriser, 2015.; Adeel, 2014.; Kovacova i Vackova, 2015. i dr.) jesu kako elementi računalnih igara pozitivno utječu na motivaciju studenata. U *gemificiranim* obrazovnim sustavima očekuje se kako bi elementi računalnih igara (estetika, mehanika i dinamika) iz **tablice 24.** (poglavlje 4.2.), mogli studente još više zainteresirati za nastavne materijale, čime bi se studenti duže zadržavali u e-tečaju. Pretpostavka jest da ako je korisnik duže u interakciji s određenim nastavnim materijalom, taj isti nastavni materijal će bolje naučiti, te će buduće učenje biti brže, a znanje dugoročnije. Bitno je naglasiti kako **podhipoteza H1.1** u analizu rezultata ne uključuje nenastavne materijale, te komunikacijske i zabavne elemente koji su dostupni u *eksperimentalnom* e-tečaju.

Prva podhipoteza ove disertacije glasi:

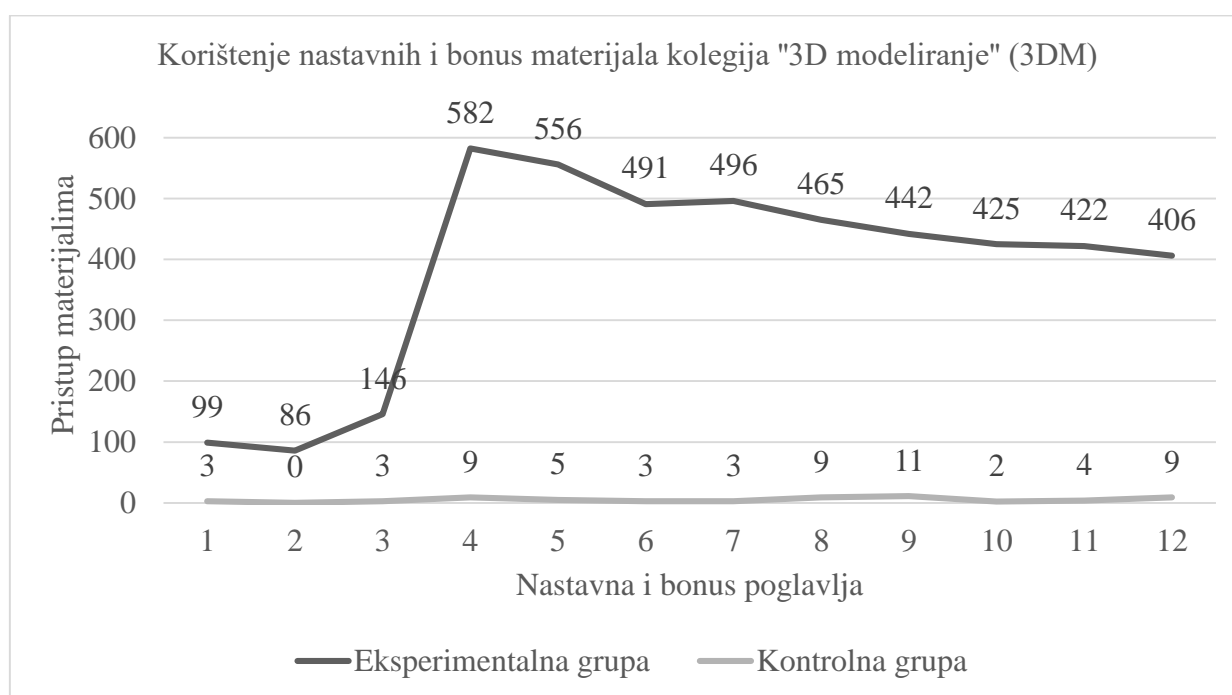
H1.1. Elementi računalnih igara, koji su uključeni u *eksperimentalni* e-tečaj, **pozitivno utječu na veće korištenje nastavnih materijala**, u usporedbi s *klasičnim* e-tečajem koji sadrži identične nastavne materijale, bez prisutnosti elemenata računalnih igara.

Studenti kolegija "3D modeliranje" sve do provedbe ovog doktorskog istraživanja nisu za potrebe kolegija koristili e-tečaj. Nakon objašnjenja istraživanja i provedbe *predtest* provjere znanja, studenti su po prvi puta na kolegiju uključeni u *kontrolni* ili *eksperimentalni* e-tečaj. Ranije, u **poglavlju 5.5.** objašnjeno je kako su studenti jedne grupe na vježbama ujedno i jedna grupa u istraživanju, što znači kako unutar kolegija "3D modeliranje" postoje ukupno **četiri grupe** ispitanika i to dvije *kontrolne* i dvije *eksperimentalne*. U provedenom *predistraživanju* unutar kolegija "3D modeliranje", korišteno je ukupno 12 nastavnih i bonus materijala koje su studenti imali na raspolaganju minimalno 14 dana. Izdvojeni nastavni materijali nalaze se u tablici 64. ovog poglavlja.

Tvrdnja podhipoteze H1.1 je potvrđena. Odluka se temelji na tabličnoj i grafičkoj analizi objektivnih pokazatelja koji su generirani pomoću *log* zapisa iz Moodle sustava, te se navode u nastavku ove doktorske disertacije unutar tablice 65. i slike 44.

Tablica 65. Usporedni prikaz korištenja nastavnih i bonus materijala u kolegiju "3DM"

Nastavna poglavlja kolegija "3D modeliranje"	Eksperimentalna grupa	Kontrolna grupa
1. Video - Maya Learning Channel	99	3
2. Poglavlje - Uvod u Mayu 2014	86	0
3. Nastavno poglavlje: Mental ray 1	146	3
4. Nastavno poglavlje: Osnove osvjetljenja	582	9
5. Nastavno poglavlje: Indirektno osvjetljenje 1	556	5
6. Nastavno poglavlje: Indirektno osvjetljenje 2	491	3
7. Bonus nastavni sadržaj: Život poslije PI	496	3
8. Nastavno poglavlje: Osvjetljenje i renderiranje	465	9
9. Nastavno poglavlje: Mental Ray 2	442	11
10. Nastavno poglavlje: Maya i Keyshot	425	2
11. Bonus nastavni sadržaj: IBL	422	4
12. Bonus nastavni sadržaj: Renderiranje u slojevima	406	9
Ukupna aktivnost nad nastavnim i bonus materijalima	4616	61



Slika 44. Grafički prikaz korištenja nastavnih i bonus materijala u kolegiju "3DM"

- ❖ **Kontrolni** e-tečaj u sebi nije imao ništa osim mogućnosti korištenja *avata*ra, *foruma*, te *nelinearnog pristupa* navedenim nastavnim materijalima. Tablica 65. i slika 44. prikazuju gotovo konstantnu nezainteresiranost za nastavnim materijalima kod *kontrolne* skupine ispitanika. Izgled e-tečaja prikazan je na **slici 27**. Izgled e-tečaja bio je **vizualno neprivlačan**, te nije uključivao **niti jedan dodatni element** računalnih igara osim već spomenutog *avata*ra, *foruma* te *nelinearnog pristupa* nastavnim sadržajima.

❖ *Eksperimentalni* e-tečaj sadrži **elemente računalnih igara** koji su prikazani unutar tablice 26. (poglavlje 4.3.), te su služili kao potpora nastavnim materijalima koji se navode u tablici 65. Studentska aktivnost nad uvodnim poglavljima bilježi slabiji odaziv koji se može objasniti **predznanjem** studenata, isto kao i mogućim **prijelaznim razdobljem**, s obzirom na to kako studenti u okviru kolegija "3D modeliranje" do trenutka provođenja ovog istraživanja nisu koristili e-tečaj kao primarni izvor nastavnih materijala. Nakon upoznavanja s korištenjem i mogućnostima sustava, studentska aktivnost **gotovo je pet puta veća** u odnosu na uvodna poglavlja, te je **65 puta** veća u odnosu na *kontrolnu* skupinu ispitanika što je vidljivo u grafičkom prikazu slike 44. Interes za nastavnim materijalima kod *eksperimentalne* grupe ispitanika iznimno je visok, što bi se jedino moglo objasniti razlikom u dizajnu između *kontrolnog* i *eksperimentalnog* e-tečaja. *Eksperimentalni* e-tečaj vizualno je privlačan, te sadrži elemente računalnih igara koji su prikazani u tablici 26.

S obzirom na objektivne rezultate generirane temeljem *log* zapisa o aktivnostima nad nastavnim i bonus materijalima iz Moodle sustava koji je korišten u *predistraživanju*, može se zaključiti kako elementi računalnih igara, koji su uključeni u *eksperimentalni* e-tečaj, **utječu na veće korištenje nastavnih materijala** čime se potvrđuje podhipoteza H1.1 ove doktorske disertacije.

Druga hipoteza ove disertacije glasi:

H2. E-tečaj dizajniran uz primjenu elemenata računalnih igara omogućuje **postizanje boljih rezultata** polaznika u odnosu na tradicionalne pristupe e-učenju, imajući u vidu razinu **stečenog znanja** iz određenog nastavnog sadržaja.

Kako bi se potvrdila hipoteza H2, potrebno je osigurati uvjete za testiranje razine stečenog znanja iz određenog nastavnog sadržaja.

- **Prvi korak** odnosio se na odabir ispitanika koji su se rasporedili u četiri odvojene grupe. Svaka grupa imala je odvojen termin unutar kojeg su ispitanici izvršavali aktivnosti vezane uz kolegij i istraživanje.
- **Drugi korak** odnosio se na provjeru jesu li grupe statistički podjednake. Na temelju ostvarenih bodova provjerava se statistička značajnost i donosi zaključak o zadovoljavanju početnih uvjeta istraživanja.

Predznanje iz područja informatike i računalne grafike mjereno je *predtestom* koji broji 32 pitanja. Nakon testiranja **statističke značajnosti razlike** metodom t-testa, između rezultata *predtesta eksperimentalne (G1)* grupe (N=15) i *kontrolne (G2)* grupe (N=13) utvrđeno je kako **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*. Ista procedura ponovljena je i za ispitanike *eksperimentalne (G4)* i *kontrolne (G3)* grupe, **gdje se nameće zaključak kako ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*. Također je provedeno testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta svih ispitanika eksperimentalne (G1, G4; N=28)* i *kontrolne (G2, G3; N=27)* grupe, gdje je utvrđeno kako **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*.

Na temelju rezultata *predtesta* zaključuje se kako se grupe statistički značajno ne razlikuju, te se ukazuje na mogućnost dolaska do statistički značajnih razlika u *eksperimentalnom* programu. Obje *eksperimentalne (G1, G4; N=28)* i *kontrolne (G2, G3; N=27)* grupe ispitanika upućene su u odvojene sustave gdje su izvršavale određene nastavne aktivnosti. Nastavni sadržaji nisu bili mijenjani tijekom rada, niti su se razlikovali na bilo koji način. *Klasičan* e-tečaj kreiran je prema uzoru na opće prihvaćene tečaje koji se koriste na Sveučilištu sjever i Sveučilištu u Zagrebu. Gemificirani *eksperimentalni* e-tečaj kreiran je na temelju principa računalnih igara. Pokušalo se obuhvatiti što je više moguće elemenata računalnih igara koje bi na direktan ili indirektan način mogli utjecati na korisnikovo ponašanje ili motivaciju. Sustav je kreiran prema eRIOOS gemificiranom modelu.

Tablica 66. Usporedni prikaz testiranja **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta* i rezultata *posttesta* kod **svih ispitanika eksperimentalne (G1, G4; N=28)** i **kontrolne (G2, G3; N=27)** grupe

Testiranje	Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
<i>Predtest</i>	G1, G4	28	16,00	5,19	0,48	0,6328
	G2, G3	27	15,37	4,48		
<i>Posttest</i>	G1, G4	28	20,89	5,78	3,99	0,0002
	G2, G3	27	15,30	4,50		

- U **trećem koraku** polaznici oba e-tečaja nastavne su materijale proučavali isključivo kroz e-tečaj. Teme tečaja nisu prezentirane na predavanjima, niti na laboratorijskim vježbama. Korištenje e-tečajeve trajalo je minimalno 14 dana nakon čega je uslijedilo testiranje stečenog znanja primjenom *posttest* instrumenta.

Testiranje **statističke značajnosti razlike** metodom t-testa provodilo se između istih skupina ispitanika i to između *eksperimentalne* (G1) grupe (N=15) i *kontrolne* (G2) grupe (N=13), gdje je izračunata **p vrijednost** iznosila **0,005**, prema kojoj se može zaključiti, uz mogućnost pogreške od 1%, kako između prve *eksperimentalne* (G1) i prve *kontrolne* (G2) grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*. Nastavilo se testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta* *eksperimentalne* (G4) grupe (N=13) i *kontrolne* (G3) grupe (N=14), gdje se može zaključiti, uz mogućnost pogreške od 5%, kako između navedenih ispitanika **postoji statistički značajna razlika**. Finalna faza provjere, prikazana unutar tablice 66., jest testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta* **svih ispitanika** *eksperimentalne* (G1, G4; N=28) i *kontrolne* (G2, G3; N=27) grupe, gdje izračunata **p vrijednost** iznosila **0,0002**, prema kojoj se može zaključiti, uz mogućnost pogreške od 1%, kako između svih ispitanika *eksperimentalne* (G1, G4) grupe te svih ispitanika *kontrolne* (G2, G3) grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*. *Eksperimentalna* grupa ostvarila je **bolji rezultat za 36,55%**, čime je **prihvaćena tvrdnja hipoteze H2**.

Druga podhipoteza ove disertacije glasi:

H2.1. *Eksperimentalna* grupa ispitanika, koja je u *pretest* provjeri znanja ostvarila **minimalno 50%** bodova, postići će **statistički značajnije** rezultate u odnosu na *kontrolnu* grupu ispitanika, koja je u *pretest* provjeri znanja ostvarila **minimalno 50%** bodova, s obzirom na ostvarene bodove u *posttest* provjeri znanja.

Za potrebe potvrđivanja podhipoteze H2.1, napravljena je dodatna analiza bodova samo nad ispitanicima koji su zadovoljili dodatni uvjet koji je vezan za ostvarivanje **minimalno 50% ukupnih bodova** u provedenom *pretestu predistraživanja*. Od ukupnog broja ispitanika njih 25 je zadovoljilo navedeni uvjet. Provedena je analiza *posttest* provjere znanja temeljem ukupno ostvarenih bodova (ukupno 32 pitanja), koja je detaljno prikazana u **poglavlju 6.1.2**. Rezultat skraćene analize nalazi se u tablici 67. u nastavku ove doktorske disertacije.

Tvrdnja podhipoteze H2.1 je potvrđena. Odluka se temelji na analizi *posttest* provjere znanja koja se u skraćenom obliku navodi u nastavku ove doktorske disertacije.

Tablica 67. Skraćeni prikaz analize odgovora iz *posttesta* provjere *predistraživanja*

Grupa ispitanika	Ukupni rezultat (uk. broj pitanja = 32)	
	Eksp.	Kont.
Prosjeck bodova	23,58	16,77
Stand. devijacija	5,42	5,04
Broj ispitanika	12	13
t vrijednost	3,26	
p vrijednost	0,003	

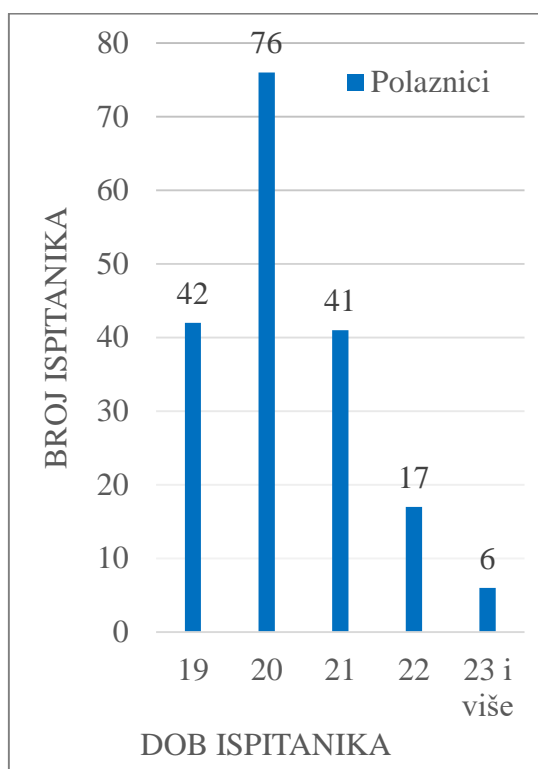
*Eksp. = *eksperimentalna* grupa, *Kont. = *kontrolna* grupa

Unutar tablice 67. navode se bodovi za sva pitanja *posttest* provjere znanja (ukupno 32 pitanja), koja su bila *eksperimentalnoj* i *kontrolnoj* grupi na raspolaganju te je nad njima provedena t-test analiza. Izračunata **t vrijednost iznosila je 3.26**, dok je **p vrijednost iznosila 0.003**, čime se zaključuje kako između ispitanika *eksperimentalne* (N=12) i *kontrolne* (N=13) grupe ispitanika **postoji statistički značajna razlika**. Prosječan broj bodova u *posttest* provjeri znanja u *eksperimentalnoj* grupi ispitanika, bio je za **40.61%** veći u odnosu na *kontrolnu* grupu ispitanika.

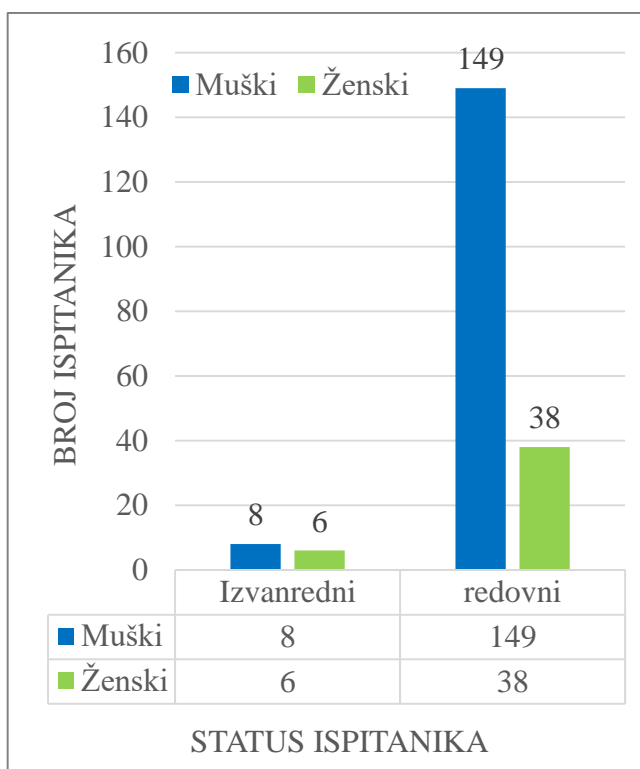
Obzirom na rezultat prosječnih bodova *posttest* provjere znanja u okviru *predistraživanja*, gdje su analizirani rezultati samo onih ispitanika koji su ostvarili **minimalno 50% od ukupnih** bodova, zaključuje se kako između ispitanika *eksperimentalne* (N=12) i *kontrolne* (N=13) grupe ispitanika **postoji statistički značajna razlika**, čime se i potvrđuje podhipoteza H2.1 ove doktorske disertacije.

6.2. PRVO GLAVNO ISTRAŽIVANJE: E-TEČAJ "HRPA I STOG"

Ispitanici u prvom glavnom istraživanju bili su studenti **Fakulteta organizacije i informatike** u Varaždinu koji su pohađali kolegij "**Programiranje 2**", (skraćenog naziva **PRO**), preddiplomskog studija informacijskih znanosti u zimskom semestru akademske godine 2015./2016. **Ukupan broj** ispitanika, koji je dobrovoljno sudjelovao u istraživanju, bio je **201**. Ispitanici su bili podijeljeni u **14 skupina** po **15 studenata** u grupi. Od navedenog ukupnog broja ispitanika, 44 ili 21,89% je bilo ženskog, a 157 ili 78,11% muškog spola. Prosječna dob ispitanika bila je 20 godina. *Anketni upitnik* u cijelosti je ispunilo **182** studenata. Detaljniji uvid u strukturu ispitanika prikazan je na slikama 45. i 46.



Slika 45. Dob ispitanika kolegija "Programiranje 2" (N=182)



Slika 46. Status ispitanika kolegija "Programiranje 2" (N=201)

6.2.1. Predtest analiza rezultata u provedenom prvom glavnom istraživanju

Polaznici kolegija "**Programiranje 2**", e-tečaja "**Hrpa i stog**" primili su upute kako pristupiti ispunjavanju *predtest provjeri znanja* kojom se provjeravalo predznanje studenata. Studenti su prema evidenciji na vježbama, podijeljeni u **14 grupa**, što je vidljivo u tablicama 68. i 69. Sedam *eksperimentalnih* grupa su: **G2, G3, G5, G7, G11, G12, G14**. Sedam *kontrolnih* grupa su: **G1, G4, G6, G8, G9, G10, G13**. Uslijedila je provjera jednakosti između svih grupa.

Tablica 68. Usporedni prikaz *eksperimentalnih* grupa nakon *predtesta* za provjeru znanja

Grupa 2 - Eksperimentalna grupa (G2)			Grupa 3 - Eksperimentalna grupa (G3)		
N = 15			N = 14		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
28	12	40,00	59	17	56,67
30	14	46,67	62	18	60,00
33	6	20,00	64	19	63,33
34	13	43,33	65	19	63,33
35	20	66,67	66	20	66,67
36	26	86,67	68	14	46,67
37	18	60,00	69	17	56,67
38	16	53,33	71	21	70,00
40	17	56,67	72	20	66,67
42	15	50,00	73	15	50,00
43	15	50,00	74	16	53,33
44	16	53,33	78	19	63,33
46	15	50,00	103	12	40,00
63	11	36,67	129	15	50,00
108	20	66,67			
Prosječni bodovi grupe: 15,600			Prosječni bodovi grupe: 17,285		
Grupa 5 - Eksperimentalna grupa (G5)			Grupa 7 - Eksperimentalna grupa (G7)		
N = 15			N = 13		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
7	15	50,00	27	15	50,00
8	12	40,00	58	16	53,33
9	15	50,00	67	24	80,00
12	18	60,00	70	12	40,00
14	13	43,33	75	14	46,67
19	19	63,33	77	9	30,00
20	12	40,00	79	16	53,33
21	10	33,33	80	16	53,33
23	17	56,67	81	21	70,00
25	15	50,00	82	13	43,33
26	11	36,67	83	14	46,67
48	24	80,00	173	8	26,67
171	15	50,00	178	16	53,33
177	15	50,00			
181	14	46,67			
Prosječni bodovi grupe: 15,000			Prosječni bodovi grupe: 14,923		

Grupa 11 - Eksperimentalna grupa (G11)

N = 13

Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
144	10	33,33
158	20	66,67
159	17	56,67
160	15	50,00
161	14	46,67
162	12	40,00
163	13	43,33
164	20	66,67
165	13	43,33
166	10	33,33
167	16	53,33
190	9	30,00
182	17	56,67

Prosječni bodovi grupe: 14,307**Grupa 12 - Eksperimentalna grupa (G12)**

N = 15

Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
22	10	33,33
53	19	63,33
55	14	46,67
122	11	36,67
168	28	93,33
169	10	33,33
170	10	33,33
172	14	46,67
174	16	53,33
175	16	53,33
176	11	36,67
195	13	43,33
199	21	70,00
193	28	93,33
184	19	63,33

Prosječni bodovi grupe: 16,000**Grupa 14 - Eksperimentalna grupa (G14)**

N = 14

Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
31	15	50,00
147	14	46,67
148	17	56,67
149	12	40,00
150	14	46,67
151	21	70,00
152	20	66,67
153	21	70,00
154	13	43,33
155	15	50,00
156	15	50,00
157	19	63,33
197	7	23,33
201	17	56,67

Prosječni bodovi grupe: 15,714

Tablica 69. Usporedni prikaz kontrolnih grupa nakon predtesta za provjeru znanja

Grupa 1 - Kontrolna grupa (G1) N = 15			Grupa 4 - Kontrolna grupa (G4) N = 14		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
1	17	56,67	32	11	36,67
2	13	43,33	91	12	40,00
3	18	60,00	94	12	40,00
4	22	73,33	98	16	53,33
5	14	46,67	99	15	50,00
6	19	63,33	101	15	50,00
10	23	76,67	102	11	36,67
11	19	63,33	104	13	43,33
13	11	36,67	105	15	50,00
15	19	63,33	106	7	23,33
16	16	53,33	107	12	40,00
17	17	56,67	109	19	63,33
18	17	56,67	186	14	46,67
131	15	50,00	187	15	50,00
185	16	53,33			
Prosječni bodovi grupe: 17,066			Prosječni bodovi grupe: 13,357		
Grupa 6 - Kontrolna grupa (G6) N = 14			Grupa 8 - Kontrolna grupa (G8) N = 15		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
24	18	60,00	60	20	66,67
29	17	56,67	84	19	63,33
39	19	63,33	85	19	63,33
41	14	46,67	86	12	40,00
45	17	56,67	87	19	63,33
47	10	33,33	88	16	53,33
49	22	73,33	89	15	50,00
50	12	40,00	90	14	46,67
51	18	60,00	92	11	36,67
52	13	43,33	93	15	50,00
54	19	63,33	95	16	53,33
56	17	56,67	96	14	46,67
57	9	30,00	97	7	23,33
183	15	50,00	100	20	66,67
			200	7	23,33
Prosječni bodovi grupe: 15,714			Prosječni bodovi grupe: 14,933		

Grupa 9 - Kontrolna grupa (G9)

N = 15

Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
110	9	30,00
111	13	43,33
112	22	73,33
113	14	46,67
114	21	70,00
115	13	43,33
116	9	30,00
117	10	33,33
118	17	56,67
119	15	50,00
120	14	46,67
121	14	46,67
123	14	46,67
124	11	36,67
125	23	76,67

Prosječni bodovi grupe: 14,600**Grupa 10 - Kontrolna grupa (G10)**

N = 15

Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
61	17	56,67
76	17	56,67
139	20	66,67
140	12	40,00
141	15	50,00
142	17	56,67
143	18	60,00
145	13	43,33
146	16	53,33
179	8	26,67
180	18	60,00
188	14	46,67
189	14	46,67
196	14	46,67
198	17	56,67

Prosječni bodovi grupe: 15,333**Grupa 13 - Kontrolna grupa (G13)**

N = 14

Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
126	21	70,00
127	14	46,67
128	9	30,00
130	14	46,67
132	19	63,33
133	17	56,67
134	19	63,33
135	16	53,33
136	10	33,33
137	20	66,67
138	10	33,33
191	15	50,00
192	15	50,00
194	20	66,67

Prosječni bodovi grupe: 15,642

Tablica 70. Rezultati *predtesta* za sve ispitanike *eksperimentalne* grupe (N=99)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	15,57	4,17	15	6-28

Tablica 70. prikazuje rezultate *predtesta* za provjeru znanja kod **svih ispitanika** grupiranih unutar *eksperimentalne* (**G2, G3, G5, G7, G11, G12, G14**) grupe. Prosječna vrijednost bodova koju je grupa postigla iznosi 15,57, uz standardnu devijaciju od 4,17. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 15. Raspon bodova kreće se od minimalno 6 do maksimalno 28.

Tablica 71. Rezultati *predtesta* za sve ispitanike *kontrolne* grupe (N=102)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	15,25	3,72	14	7-23

Rezultati *predtesta* za provjeru znanja kod **svih ispitanika** grupiranih unutar *kontrolne* (**G1, G4, G6, G8, G9, G10, G13**) grupe, prikazani su u tablici 71. Prosječna vrijednost bodova iznosi 15,25, uz standardnu devijaciju od 3,72. Najčešći iznos (Mod) sakupljenih bodova iznosi 14. Raspon bodova koji su ispitanici ostvarili iznosi od 7 do 23.

U nastavku rada prikazano je ukupno sedam tablica (tablica 72. do 78.) u kojima se prikazuje usporedba između *eksperimentalnih* i *kontrolnih* grupa prema rasporedu u nastavku. Tablica 72. prikazuje grupe G2 i G8; Tablica 73. prikazuje grupe G3 i G9; Tablica 74. prikazuje grupe G5 i G13; Tablica 75. prikazuje grupe G7 i G4; Tablica 76. prikazuje grupe G11 i G10; Tablica 77. prikazuje grupe G12 i G1, te Tablica 78. prikazuje grupe G14 i G6. Navedeni odnos između grupa osigurava jednake početne uvjete između *eksperimentalnih* i *kontrolnih* grupa.

Tablica 72. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta* *eksperimentalne* (**G2**) grupe (N=15) i *kontrolne* (**G8**) grupe (N=15)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G2	15	15,60	4,56	0,41	0,6826
G8	15	14,93	4,27		

Tablica 72. prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja. Izračun se temelji na usporedbi *eksperimentalne* (**G2**) i *kontrolne* (**G8**) grupe. Intermedijalna **t vrijednost** iznosi **0,41**. Izračunata **p vrijednost** iznosi **0,68** čime se može zaključiti kako između *eksperimentalne* (**G2**) i *kontrolne* (**G8**) grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*.

Tablica 73. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta eksperimentalne (G3)* grupe (N=14) i *kontrolne (G9)* grupe (N=15)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G3	14	17,29	2,61	1,96	0,0595
G9	15	14,60	4,44		

Tablica 73. prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja. Izračun se temelji na usporedbi *eksperimentalne (G3)* grupe i *kontrolne (G9)* grupe ispitanika. Intermedijalna **vrijednost t** iznosi **1,96**. Izračunata **p vrijednost** iznosi **0,059** čime se može zaključiti kako niti između navedenih ispitanika *eksperimentalne (G3)* i *kontrolne (G9)* grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*.

Tablica 74. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta eksperimentalne (G5)* grupe (N=15) i *kontrolne (G13)* grupe (N=14)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G5	15	15,00	3,53	0,46	0,6481
G13	14	15,64	3,97		

Tablica 74. prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja. Izračun se temelji na usporedbi *eksperimentalne (G5)* i *kontrolne (G13)* grupe. Intermedijalna **t vrijednost** iznosi **0,46**. Izračunata **p vrijednost** iznosi **0,64** čime se može zaključiti kako između *eksperimentalne (G5)* i *kontrolne (G13)* grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*.

Tablica 75. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta eksperimentalne (G7)* grupe (N=13) i *kontrolne (G4)* grupe (N=14)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G7	13	14,92	4,29	1,12	0,2724
G4	14	13,36	2,87		

Tablica 75. prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja. Izračun se temelji na usporedbi *eksperimentalne (G7)* grupe i *kontrolne (G4)* grupe ispitanika. Intermedijalna **vrijednost t** iznosi **1,12**. Izračunata **p vrijednost** iznosi **0,27** čime se može zaključiti kako niti u ovom slučaju između navedenih ispitanika *eksperimentalne (G7)* i *kontrolne (G4)* grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*.

Tablica 76. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta eksperimentalne (G11)* grupe (N=13) i *kontrolne (G10)* grupe (N=15)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G11	13	14,31	3,61	0,82	0,4171
G10	15	15,33	2,97		

Tablica 76. prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja. Izračun se temelji na usporedbi *eksperimentalne (G11)* i *kontrolne (G10)* grupe. Intermedijalna **t vrijednost** iznosi **0,82**. Izračunata **p vrijednost** iznosi **0,41** čime se može zaključiti kako između *eksperimentalne (G11)* i *kontrolne (G10)* grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*.

Tablica 77. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta eksperimentalne (G12)* grupe (N=15) i *kontrolne (G1)* grupe (N=15)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G12	15	16,00	6,01	0,60	0,5483
G1	15	17,07	3,17		

Tablica 77. prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja. Izračun se temelji na usporedbi *eksperimentalne (G12)* grupe i *kontrolne (G1)* grupe ispitanika. Intermedijalna **vrijednost t** iznosi **0,60**. Izračunata **p vrijednost** iznosi **0,54** čime se može zaključiti kako niti između navedenih ispitanika *eksperimentalne (G12)* i *kontrolne (G1)* grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*.

Tablica 78. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta eksperimentalne (G14)* grupe (N=14) i *kontrolne (G6)* grupe (N=14)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G14	14	15,71	3,85	0,00	1,0000
G6	14	15,71	3,71		

Tablica 78. prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja. Izračun se temelji na usporedbi sedme *eksperimentalne (G14)* i sedme *kontrolne (G6)* grupe. Intermedijalna **t vrijednost** iznosi **0,00**. Izračunata **p vrijednost** iznosi **1,00** čime se može zaključiti kako između sedme *eksperimentalne (G14)* i sedme *kontrolne (G6)* grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*.

Tablica 79. Usporedni prikaz analize bodova između **ispitanika eksperimentalne** i **kontrolne** grupe polaznika u provedenoj *predtest* provjeri znanja

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	p
G2	15	15,60	4,56	0,6826
G8	15	14,93	4,27	
G3	14	17,29	2,61	0,0595
G9	15	14,60	4,44	
G5	15	15,00	3,53	0,6481
G13	14	15,64	3,97	
G7	13	14,92	4,29	0,2724
G4	14	13,36	2,87	
G11	13	14,31	3,61	0,4171
G10	15	15,33	2,97	
G12	15	16,00	6,01	0,5483
G1	15	17,07	3,17	
G14	14	15,71	3,85	1,0000
G6	14	15,71	3,71	

Tablica 79. prikazuje odnos između ranije formiranih parova te ukazuje kroz izračun statističke značajnosti ukazuje na podjednakost između grupa. Izračunate **p vrijednosti** ukazuju kako između parova grupa **ne postoji statistički značajna razlika**.

Tablica 80. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta svih ispitanika eksperimentalne* (G_E) grupe, (N=99) i *kontrolne* (G_K) grupe, (N=102)

Ispitanici	Broj ispitanika	Prosječna vrijednost M	Standardna devijacija σ	t	p
G_E	99	15,57	4,17	0,57	0,5658
G_K	102	15,25	3,72		

$G_E = G2, G3, G5, G7, G11, G12, G14; G_K = G1, G4, G6, G8, G9, G10, G13$

Tablica 80. prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja. Izračun se temelji na usporedbi svih ispitanika *eksperimentalne* (G_E) grupe te svih ispitanika *kontrolne* (G_K) grupe. Intermedijalna **vrijednost t** iznosi **0,57**. Izračunata **p vrijednost** iznosi **0,56** čime se može zaključiti kako između svih ispitanika *eksperimentalne* (G_E) grupe te svih ispitanika *kontrolne* (G_K) grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*.

6.2.2. Posttest analiza rezultata u provedenom prvom glavnom istraživanju

Polaznici kolegija "Programiranje 2", primili su upute kako pristupiti ispunjavanju *posttesta* kojim se provjeravalo znanje studenata iz sadržaja obuhvaćenih e-tečajem "Hrpa i stog". Prosječni bodovi za sve grupe nalaze se u tablicama od 81. i 82. *Eksperimentalne i kontrolne* grupe nisu bile mijenjane s obzirom na raniju postignutu jednakost između grupa.

Tablica 81. Usporedni prikaz *eksperimentalnih* grupa nakon *posttesta* za provjeru znanja

Grupa 2 - Eksperimentalna grupa (G2)			Grupa 3 - Eksperimentalna grupa (G3)		
N = 14			N = 14		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
28	9	30,00	59	10	33,33
30	7	23,33	62	17	56,67
33	8	26,67	64	16	53,33
34	22	73,33	65	20	66,67
35	23	76,67	66	21	70,00
36	8	26,67	68	7	23,33
37	11	36,67	69	23	76,67
38	23	76,67	71	22	73,33
40	6	20,00	72	8	26,67
42	11	36,67	73	15	50,00
43	8	26,67	74	23	76,67
44	7	23,33	78	17	56,67
46	14	46,67	103	9	30,00
108	9	30,00	129	12	40,00
Prosječni bodovi grupe: 11,066			Prosječni bodovi grupe: 15,714		
Grupa 5 - Eksperimentalna grupa (G5)			Grupa 7 - Eksperimentalna grupa (G7)		
N = 15			N = 12		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
7	13	43,33	27	16	53,33
8	10	33,33	58	11	36,67
9	14	46,67	67	21	70,00
12	12	40,00	70	8	26,67
14	11	36,67	77	13	43,33
19	20	66,67	79	20	66,67
20	17	56,67	80	10	33,33
21	18	60,00	81	15	50,00
23	12	40,00	82	10	33,33
25	14	46,67	83	9	30,00
26	15	50,00	173	8	26,67
48	12	40,00	178	10	33,33
171	20	66,67			
177	9	30,00			
181	9	30,00			
Prosječni bodovi grupe: 13,733			Prosječni bodovi grupe: 11,615		

Grupa 11 - Eksperimentalna grupa (G11)

N = 12

Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
144	10	33,33
159	20	66,67
160	12	40,00
161	18	60,00
162	19	63,33
163	11	36,67
164	23	76,67
165	7	23,33
166	7	23,33
167	12	40,00
190	16	53,33
182	13	43,33

Prosječni bodovi grupe: 12,923**Grupa 12 - Eksperimentalna grupa (G12)**

N = 15

Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
22	14	46,67
53	26	86,67
55	22	73,33
122	21	70,00
168	27	90,00
169	19	63,33
170	9	30,00
172	20	66,67
174	14	46,67
175	8	26,67
176	21	70,00
195	10	33,33
199	7	23,33
193	20	66,67
184	13	43,33

Prosječni bodovi grupe: 16,733**Grupa 14 - Eksperimentalna grupa (G14)**

N = 14

Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
31	12	40,00
147	11	36,67
148	15	50,00
149	10	33,33
150	16	53,33
151	5	16,67
152	19	63,33
153	9	30,00
154	21	70,00
155	15	50,00
156	10	33,33
157	14	46,67
197	5	16,67
201	9	30,00

Prosječni bodovi grupe: 12,214

Tablica 82. Usporedni prikaz kontrolnih grupa nakon *posttesta* za provjeru znanja

Grupa 1 - Kontrolna grupa (G1) N = 15			Grupa 4 - Kontrolna grupa (G4) N = 13		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
1	12	40,00	32	13	43,33
2	14	46,67	91	11	36,67
3	12	40,00	94	9	30,00
4	11	36,67	98	14	46,67
5	13	43,33	99	17	56,67
6	15	50,00	101	21	70,00
10	17	56,67	102	6	20,00
11	12	40,00	104	11	36,67
13	10	33,33	105	16	53,33
15	21	70,00	106	16	53,33
16	13	43,33	107	17	56,67
17	10	33,33	186	5	16,67
18	8	26,67	187	10	33,33
131	9	30,00			
185	9	30,00			
Prosječni bodovi grupe: 12,400			Prosječni bodovi grupe: 11,857		
Grupa 6 - Kontrolna grupa (G6) N = 13			Grupa 8 - Kontrolna grupa (G8) N = 14		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
24	17	56,67	60	10	33,33
29	11	36,67	84	13	43,33
39	13	43,33	85	12	40,00
41	10	33,33	86	15	50,00
45	11	36,67	87	11	36,67
47	7	23,33	88	17	56,67
50	14	46,67	89	10	33,33
51	8	26,67	90	12	40,00
52	19	63,33	93	12	40,00
54	9	30,00	95	12	40,00
56	7	23,33	96	15	50,00
57	6	20,00	97	11	36,67
183	11	36,67	100	18	60,00
			200	15	50,00
Prosječni bodovi grupe: 10,214			Prosječni bodovi grupe: 12,200		

Grupa 9 - Kontrolna grupa (G9)

N = 15

Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
110	12	40,00
111	8	26,67
112	23	76,67
113	19	63,33
114	14	46,67
115	9	30,00
116	10	33,33
117	7	23,33
118	10	33,33
119	17	56,67
120	9	30,00
121	10	33,33
123	6	20,00
124	16	53,33
125	15	50,00

Prosječni bodovi grupe: 12,333**Grupa 10 - Kontrolna grupa (G10)**

N = 13

Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
61	7	23,33
76	15	50,00
139	13	43,33
140	6	20,00
141	6	20,00
142	22	73,33
143	10	33,33
145	6	20,00
179	11	36,67
180	13	43,33
189	18	60,00
196	11	36,67
198	11	36,67

Prosječni bodovi grupe: 9,933**Grupa 13 - Kontrolna grupa (G13)**

N = 13

Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
126	11	36,67
127	11	36,67
128	7	23,33
130	7	23,33
132	14	46,67
133	7	23,33
134	10	33,33
135	4	13,33
136	10	33,33
137	18	60,00
138	16	53,33
192	15	50,00
194	13	43,33

Prosječni bodovi grupe: 10,214

Tablica 83. Rezultati *posttesta* za sve ispitanike *eksperimentalne* grupe (N=96)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	13,89	5,42	9	5-27

Tablica 83. prikazuje rezultate *posttesta* za provjeru znanja kod **svih ispitanika** grupiranih unutar *eksperimentalne* (G2, G3, G5, G7, G11, G12, G14) grupe. Prosječna vrijednost bodova koju je grupa postigla iznosi 13,89 uz standardnu devijaciju od 5,42. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 9. Raspon bodova kreće se od minimalno 5 do maksimalno 27.

Tablica 84. Rezultati *posttesta* za sve ispitanike *kontrolne* grupe (N =96)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	12,03	4,05	11	4-23

Rezultati *posttesta* za provjeru znanja kod **svih ispitanika** grupiranih unutar *kontrolne* (G1, G4, G6, G8, G9, G10, G13) grupe, prikazani su u tablici 84. Prosječna vrijednost bodova iznosi 12,03 uz standardnu devijaciju od 4,05. Najčešći iznos (Mod) sakupljenih bodova iznosi 11. Raspon bodova koji su ispitanici ostvarili iznosi od 4 do 23.

U nastavku poglavlja prikazano je ukupno sedam tablica (tablica 85. do 91.) u kojima se prikazuje usporedba između *eksperimentalnih* i *kontrolnih* grupa prema rasporedu koji je objašnjen ranije u ovom poglavlju. Navedeni odnos između grupa **osigurao je jednake početne uvjete**, tj. da između *eksperimentalnih* i *kontrolnih* grupa ne postoji statistički značajna razlika što je važno zbog mogućih razlika koje mogu biti vidljive u *posttest* provjeri znanja.

Tablica 85. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta* *eksperimentalne* (G2) grupe (N=14) i *kontrolne* (G8) grupe (N=14)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G2	14	11,86	6,20	0,67	0,5033
G8	14	12,20	2,53		

Tablica 85. prikazuje izračun statističke značajnosti na temelju rezultata *posttesta* za provjeru znanja. Izračun se temelji na usporedbi *eksperimentalne* (G2) i *kontrolne* (G8) grupe. Intermedijalna **t vrijednost** iznosi **0,67**. Izračunata **p vrijednost** iznosi **0,50** čime se može zaključiti kako između *eksperimentalne* (G2) i *kontrolne* (G8) grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*.

Tablica 86. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta eksperimentalne (G3)* grupe (N=14) i *kontrolne (G9)* grupe (N=15)

Ispitanici	Broj ispitanika	Prosječna vrijednost M	Standardna devijacija σ	t	p
G3	14	15,71	5,70	1,72	0,0480
G9	15	12,33	4,85		

Tablica 86. prikazuje izračun statističke značajnosti na temelju rezultata *posttesta* za provjeru znanja. Izračun se temelji na usporedbi *eksperimentalne (G3)* grupe i *kontrolne (G9)* grupe ispitanika. Intermedijalna **vrijednost t** iznosi **0,15**. Izračunata **p vrijednost** iznosi **0,048** čime se može zaključiti, uz mogućnost pogreške od 5%, kako između navedenih ispitanika *eksperimentalne (G3)* i *kontrolne (G9)* grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*.

Tablica 87. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta eksperimentalne (G5)* grupe (N=15) i *kontrolne (G13)* grupe (N=13)

Ispitanici	Broj ispitanika	Prosječna vrijednost M	Standardna devijacija σ	t	p
G5	15	13,73	3,63	1,86	0,0364
G13	13	10,21	4,10		

Tablica 87. prikazuje izračun statističke značajnosti na temelju rezultata *posttesta* za provjeru znanja. Izračun se temelji na usporedbi *eksperimentalne (G5)* i *kontrolne (G13)* grupe. Intermedijalna **t vrijednost** iznosi **1,86**. Izračunata **p vrijednost** iznosi **0,03** čime se može zaključiti, uz mogućnost pogreške od 5%, kako između *eksperimentalne (G5)* i *kontrolne (G13)* grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*.

Tablica 88. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta eksperimentalne (G7)* grupe (N=13) i *kontrolne (G4)* grupe (N=12)

Ispitanici	Broj ispitanika	Prosječna vrijednost M	Standardna devijacija σ	t	p
G7	13	11,61	4,66	0,10	0,9200
G4	12	11,85	4,48		

Tablica 88. prikazuje izračun statističke značajnosti na temelju rezultata *posttesta* za provjeru znanja. Izračun se temelji na usporedbi *eksperimentalne (G7)* grupe i *kontrolne (G4)* grupe ispitanika. Intermedijalna **vrijednost t** iznosi **0,10**. Izračunata **p vrijednost** iznosi **0,92** čime se može zaključiti kako niti između navedenih ispitanika *eksperimentalne (G7)* i *kontrolne (G4)* grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*.

Tablica 89. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta eksperimentalne (G11)* grupe (N=12) i *kontrolne (G10)* grupe (N=13)

Ispitanici	Broj ispitanika	Prosječna vrijednost M	Standardna devijacija σ	t	p
G11	12	12,92	5,17	1,26	0,2183
G10	13	9,93	4,86		

Tablica 89. prikazuje izračun statističke značajnosti na temelju rezultata *posttesta* za provjeru znanja. Izračun se temelji na usporedbi *eksperimentalne (G11)* i *kontrolne (G10)* grupe. Intermedijalna **t vrijednost** iznosi **1,26**. Izračunata **p vrijednost** iznosi **0,21** čime se može zaključiti kako između *eksperimentalne (G11)* i *kontrolne (G10)* grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*.

Tablica 90. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta eksperimentalne (G12)* grupe (N=15) i *kontrolne (G1)* grupe (N=15)

Ispitanici	Broj ispitanika	Prosječna vrijednost M	Standardna devijacija σ	t	p
G12	15	16,73	6,47	2,29	0,0147
G1	15	12,40	3,40		

Tablica 90. prikazuje izračun statističke značajnosti na temelju rezultata *posttesta* za provjeru znanja. Izračun se temelji na usporedbi *eksperimentalne (G12)* grupe i *kontrolne (G1)* grupe ispitanika. Intermedijalna **vrijednost t** iznosi **2,29**. Izračunata **p vrijednost** iznosi **0,014** čime se može zaključiti, uz mogućnost pogreške od 5%, kako između navedenih ispitanika *eksperimentalne (G12)* i *kontrolne (G1)* grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*.

Tablica 91. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta eksperimentalne (G14)* grupe (N=14) i *kontrolne (G6)* grupe (N=13)

Ispitanici	Broj ispitanika	Prosječna vrijednost M	Standardna devijacija σ	t	p
G14	14	12,21	4,74	0,72	0,4769
G6	13	11,00	3,92		

Tablica 91. prikazuje izračun statističke značajnosti na temelju rezultata *posttesta* za provjeru znanja. Izračun se temelji na usporedbi *eksperimentalne (G14)* i *kontrolne (G6)* grupe. Intermedijalna **t vrijednost** iznosi **0,72**. Izračunata **p vrijednost** iznosi **0,47** čime se može zaključiti kako između *eksperimentalne (G14)* i *kontrolne (G6)* grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*.

Tablica 92. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta svih ispitanika eksperimentalne* (G_E) grupe, ($N=96$) i *kontrolne* (G_K) grupe, ($N=96$)

Ispitanici	Broj ispitanika	Prosječna vrijednost M	Standardna devijacija σ	t	p
G_E	96	13,89	5,42	2,68	0,0079
G_K	96	12,03	4,05		

$G_E = G_2, G_3, G_5, G_7, G_{11}, G_{12}, G_{14}; G_K = G_1, G_4, G_6, G_8, G_9, G_{10}, G_{13}$

Tablica 92. prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja. Izračun se temelji na usporedbi svih ispitanika *eksperimentalne* (G_E) grupe te svih ispitanika *kontrolne* (G_K) grupe. Intermedijalna **vrijednost t** iznosi **2,68**. Izračunata **p vrijednost** iznosi **0,007** čime se može zaključiti, uz mogućnost pogreške od 1%, kako između svih ispitanika *eksperimentalne* (G_E) grupe te svih ispitanika *kontrolne* (G_K) grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*.

Prosječan broj bodova prije eksperimenta za *eksperimentalnu grupu* iznosio je **15,54**, dok je za *kontrolnu grupu* iznosio **15,23**. *Eksperimentalna* grupa postigla je bolji rezultat za **2,03%**. Pomoću *predtest provjere znanja* i dobivenih pokazatelja, izračunate su **p vrijednosti** na temelju kojih se vidi kako **između grupa ne postoji statistički značajna razlika**. *Eksperimentalne* grupe pristupile su *gemificiranom* e-tečaju, dok su *kontrolne* grupe pristupile *klasičnom* e-tečaju koji je studentima bio na raspolaganju minimalno 14 dana. U prvom tjednu nakon korištenja e-tečaja slijedi **posttest provjera znanja**. Prosječan broj bodova nakon eksperimenta se za *eksperimentalnu grupu* smanjio za **11,87%** te je iznosio **13,89** bodova, dok se za *kontrolnu grupu* smanjio za **26,60%** te je iznosio **12,03** bodova. *Eksperimentalna* grupa postigla je bolji rezultat za **15,46%**.

U tablici 93. ove disertacije prikazuje se dodatna analiza **otvorenog tipa** pitanja *posttest* provjere znanja u provedenom *prvom glavnom istraživanju*. Izračunat je prosjek, standardna devijacija, te statistička značajnost rezultata. U analizu je uključena varijanta gdje se pitanjima otvorenog tipa (tj. pitanjima esejskog tipa) dodaje veći broj bodova.

Tablica 93. Analiza otvorenog tipa pitanja *posttest* provjere u *prvom glavnom istraživanju*

Grupa ispitanika	Otvoreni tip pitanja (n=5)		Otvoreni tip pitanja (n=5)*	
	Eksp.	Kont.	Eksp.	Kont.
Prosjek bodova	1,77	1,10	3,54	2,20
Stand. devijacija	1,47	1,24	2,94	2,43
t vrijednost	3,53		3,53	
p vrijednost	0,0005		0,0005	

n = broj pitanja u provjeri znanja

* = usporedni prikaz **u slučaju izmjene sustava bodova** kod pitanja otvorenog tipa

Tablica 93. pokazuje analizu otvorenog tipa pitanja iz *posttest* provjere znanja koja predstavlja dopunu ranije prezentiranih analiza iz poglavlja **6.2.2**. Vidljivo je kako *eksperimentalna* grupa ispitanika (**Eksp**), koja broji ukupno 99 ispitanika, ima **veći prosječan broj bodova**, isto kao i standardnu devijaciju u odnosu na *kontrolnu* grupu ispitanika (**Kont**), koja broji ukupno 102 ispitanika. **Statistički značajna razlika** između navedenih skupina je postignuta. Treba imati na umu kako je ovo **izdvojena analiza** nad pitanjima otvorenog tipa. Statistička značajnost, između navedenih skupina, postignuta je u i slučaju cjelokupne analize *posttest* provjere znanja.

Već je ranije obrazloženo kako svako pitanje ili zadatak u *posttest* provjeri znanja nosi **jedan bod**. U slučaju kada bi se otvoreni tip pitanja (tj. pitanja esejskog tipa) bodovao s **dva boda**, **statistička značajnost rezultata** nije bila promijenjena isto kao niti drugi pokazatelj koji bi utjecali na promjenu iznesenih zaključaka. **Standardna devijacija** i **prosječna vrijednost** bodova proporcionalno se udvostručuju čime se ne mijenja daljnji tijek analize. Zbog jednostavnosti prikaza i ranijih izračuna, odlučeno je zadržati postojeći sustav bodovanja gdje svako pitanje nosi jedan bod, bez obzira radi li se o pitanjima otvorenog ili zatvorenog tipa.

Viši ishodi učenja mjereni su samo u *prvom glavnom istraživanju* kroz zadatke otvorenog tipa u kojima su studenti trebali **otkriti** i **ispraviti** pogrešku u kodu ili **riješiti** određeni programski zadatak. Iz analize odgovora vidljivo je kako je najveća **statistički značajna razlika** postignuta upravo nad tim pitanjima, te je navedeno istraživanje ujedno imalo i **najveći uzorak** ispitanika. U nastavku analize, dodaje se još jedan kriterij koji se odnosi na selekciju studenata koji su ostvarili **minimalno 50% ukupnih bodova** u *predtest* provjeri znanja.

U provedenom *predtestu prvog glavnog istraživanja*, u okviru ovog doktorskog istraživanja, sudjelovao je 201 ispitanik. *Predtest* je brojao 30 pitanja, od kojih su 25 pitanja zatvorenog tipa i 5 pitanja otvorenog tipa. Svako pitanje nosilo je jedan bod i služilo je utvrđivanju studentovog predznanja.

Uz navedenu analizu koja je detaljno prikazana u ovom poglavlju, napravljena je dodatna analiza bodova samo nad ispitanicima koji su zadovoljili dodatni uvjet, koji je vezan za ostvarivanje **minimalno 50% ukupnih bodova** u provedenom *predtestu*. Od ukupnog broja ispitanika, njih 118 je zadovoljilo navedeni uvjet. Iz ranije definiranih grupa uklonjeni su svi studenti koji nisu imali ostvareno minimalno 50% ukupnih bodova, nakon čega su rezultati bodova ponovno analizirani.

Provedena je analiza *posttest* provjere znanja nad pitanjima **zatvorenog tipa** (ukupno 25 pitanja), nad pitanjima **otvorenog tipa** (ukupno 5 pitanja), te nad **ukupno** ostvarenim bodovima (ukupno 30 pitanja). Rezultati su uspoređivani na razini uparenih grupa, koje su i ranije korištene u ovoj doktorskoj disertaciji, isto kao i na skupnoj razini *eksperimentalne* (N=59) i *kontrolne* grupe ispitanika (N=59). U tablici 94. ovog rada vidljiv je usporedni prikaz navedenih elemenata, isto kao i podjela *posttest rezultata iz prvog glavnog istraživanja*.

Tablica 94. Usporedni prikaz analize odgovora provedenog *posttesta prvog glavnog istraživanja*

	Zatvoreni tip pitanja (uk. broj pitanja = 25)		Otvoreni tip pitanja (uk. broj pitanja = 5)		Ukupni rezultat (uk. broj pitanja = 30)	
	Eksp.	Kont.	Eksp.	Kont.	Eksp.	Kont.
Grupa ispitanika						
Prosjeck bodova	12,08	10,49	2,14	1,32	14,37	11,81
Stand. devijacija	4,99	4,39	1,59	1,17	5,88	5,07
Broj ispitanika	59	59	59	59	59	59
t vrijednost	1,84		3,17		2,53	
p vrijednost	0,068		0,002		0,012	

*Eksp. = *eksperimentalna* grupa, *Kont. = *kontrolna* grupa

Vidljivo je kako su **prosječni bodovi** veći, isto kao i standardna devijacija kod *eksperimentalne grupe* ispitanika. Izračunata p vrijednost pokazuje kako u prvom slučaju s pitanjima zatvorenog tipa ne postoji statistički značajna razlika, iako je ona granična. U druga dva slučaja, s pitanjima **otvorenog tipa** i kod **ukupne analize bodova**, izračunata p vrijednost pokazuje kako je *eksperimentalna* grupa postigla bolji rezultat koji osigurava **statistički značajnu razliku**. U nastavku ovog rada posebno se analizira uspjeh za svaki tip pitanja zbog velikog broja grupa (14) koje su bile testirane pomoću *posttest* provjere znanja.

Dodatna analiza *posttest* rezultata za **pitanja zatvorenog tipa** (n=25) u provedenom *provom glavnom istraživanju* pokazuje odnos postignutih bodova između ranije uparenih grupa, isto kao i između studenata koji su u *predtestu prvog glavnog istraživanja* postigli **50% (ili više)** od ukupnih bodova. Gotovo sve *eksperimentalne* grupe (6 od ukupno 7) imaju veći **prosječan broj** bodova od *kontrolnih* grupa po pitanju bodova za pitanja **zatvorenog tipa** (n=25) koje su studenti ostvarili kroz *posttest* provjeru znanja. Izračunata **t vrijednost iznosi 1.84**, dok je **p vrijednost 0.068**, čime se zaključuje kako između ispitanika *eksperimentalne* (N=59) i *kontrolne* (N=59) grupe ispitanika **postoji granična statistički značajna razlika**.

Dodatna analiza *posttest* rezultata za **pitanja otvorenog tipa** (n=5) u provedenom *provom glavnom istraživanju* pokazuje odnos postignutih bodova između ranije uparenih grupa, isto kao i između studenata koji su u *predtestu prvog glavnog istraživanja* postigli **50% (ili više)** od ukupnih bodova. Sve *eksperimentalne* grupe ispitanika imale su veći **prosječan broj** bodova od svih *kontrolnih* grupa, osim u slučaju kada je prosječan broj bodova između grupe 14 i grupe 6 bio izjednačen. Izračunata **t vrijednost iznosi 3.17**, dok **p vrijednost iznosi 0.0020**, čime se zaključuje kako između ispitanika *eksperimentalne* (N=59) i *kontrolne* (N=59) grupe ispitanika **postoji statistički značajna razlika**.

Dodatna analiza *posttest* rezultata za sva pitanja i **ukupan broj bodova** (n=30) u *prvom glavnom istraživanju* pokazuje odnos postignutih bodova između ranije uparenih grupa, isto kao i između studenata koji su u *predtestu prvog glavnog istraživanja* postigli **50% (ili više)** od ukupnih bodova. Evidentno je kako su **sve eksperimentalne** grupe imale veći **prosječan broj** bodova od svih *kontrolnih* grupa, temeljem **ukupnih bodova** (n=30) koje su studenti ostvarili kroz *posttest* provjeru znanja. Bodovi su sumirani te je proveden t-test kojim se utvrdilo kako **t vrijednost iznosi 2.53** dok je izračunata **p vrijednost 0.0127**, čime se zaključuje kako između ispitanika *eksperimentalne* (N=59) i *kontrolne* (N=59) grupe ispitanika **postoji statistički značajna razlika**.

U nastavku disertacije navodi se statistička analiza odgovora koji su prikupljeni iz *predtest* i *posttest* provjera znanja u provedenom *prvom glavnom istraživanju*. Izračunata je jedinična težina pitanja, prosječna težina pitanja i standardna devijacija.

Tablica 95. Analiza težine pitanja u provedenom *predtestu prvog glavnog istraživanja*

Pitanje zatvorenog tipa	Broj točnih odgovora (maks. 201 odgovora)	Težina pitanja
1	53	0,26
2	90	0,45
3	70	0,35
4	95	0,47
5	24	0,12
6	95	0,47
7	149	0,74
8	104	0,52
9	121	0,60
10	175	0,87
11	31	0,15
12	148	0,74
13	188	0,94
14	168	0,84
15	37	0,18
16	44	0,22
17	104	0,52
18	37	0,18
19	22	0,11
20	53	0,26
21	195	0,97
22	137	0,68
23	105	0,52
24	132	0,66
25	77	0,38
Prosječna težina pitanja:		0,49
Standardna devijacija:		0,27
Pitanje otvorenog tipa	Broj točnih odgovora (maks. 201 odgovora)	Težina pitanja
1	100	0,50
2	113	0,56
3	126	0,63
4	167	0,83
5	136	0,68
Prosječna težina pitanja:		0,64
Standardna devijacija:		0,13

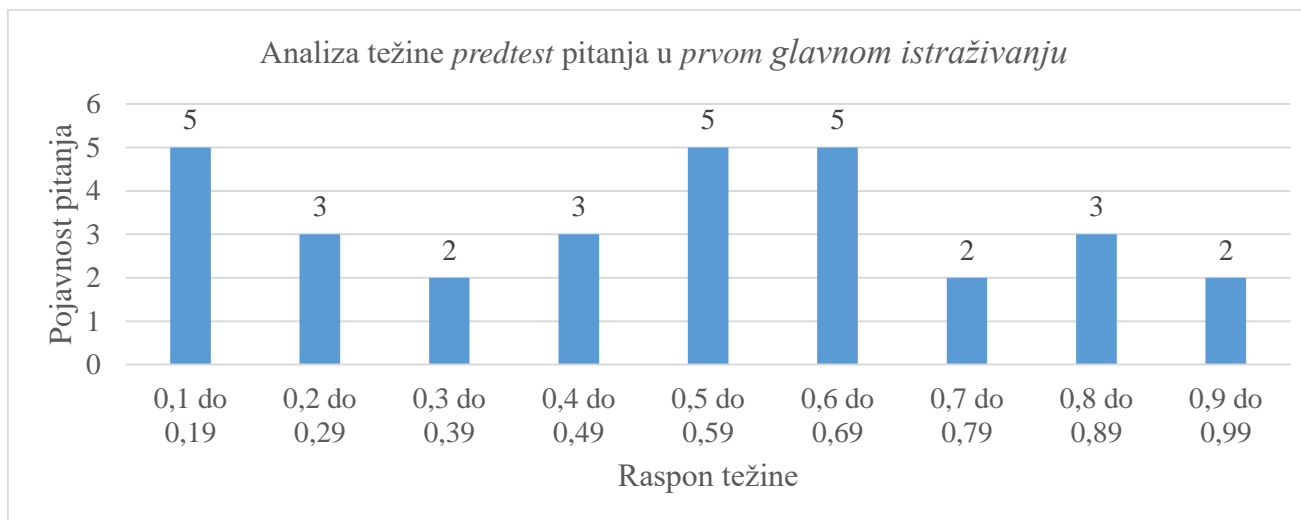
Prosječna težina pitanja **zatvorenog tipa** bila je **0,49**, dok je prosječna težina pitanja kod **otvorenog tipa** bila **0,64**. Što je vrijednost pitanja bliža 1, to je studentima pitanje bilo lakše.

U nastavku rada navodi se analiza odgovora koji su prikupljeni iz *posttest* provjere znanja koja je provedena u okviru *prvog glavnog istraživanja*.

Tablica 96. Analiza težine pitanja u provedenom *posttestu prvog glavnog istraživanja*

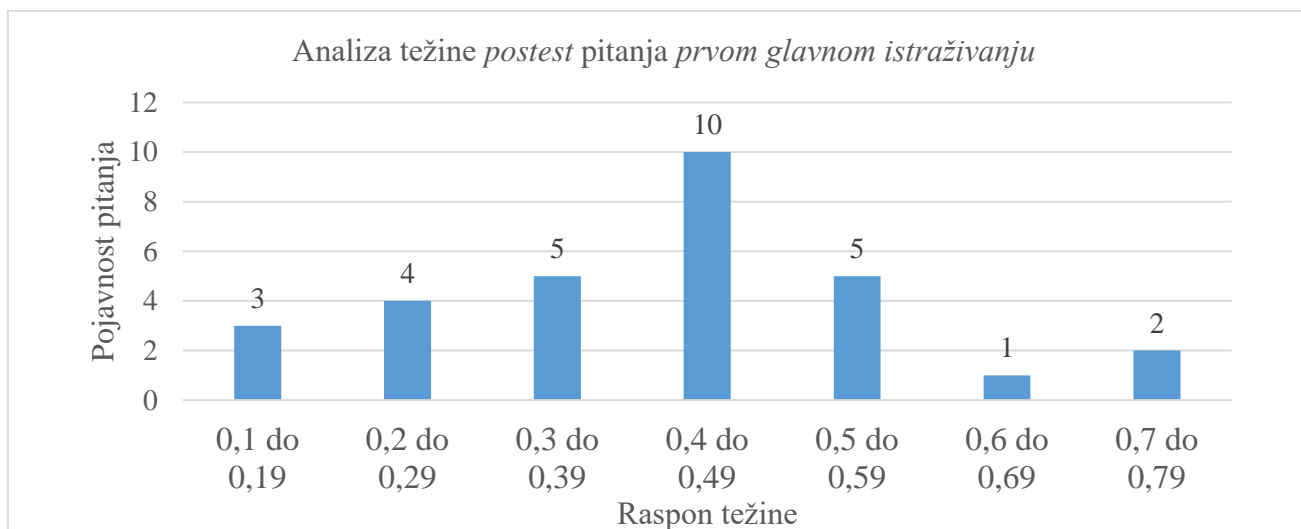
Pitanje zatvorenog tipa	Broj točnih odgovora (maks. 201 odgovora)	Težina pitanja
1	71	0,35
2	57	0,28
3	76	0,38
4	119	0,59
5	91	0,45
6	139	0,69
7	147	0,73
8	80	0,40
9	94	0,47
10	109	0,54
11	46	0,23
12	106	0,53
13	37	0,18
14	155	0,77
15	68	0,34
16	88	0,44
17	89	0,44
18	95	0,47
19	83	0,41
20	103	0,51
21	45	0,22
22	89	0,44
23	112	0,56
24	21	0,10
25	81	0,40
Prosječna težina pitanja:		0,44
Standardna devijacija:		0,16
Pitanje otvorenog tipa	Broj točnih odgovora (maks. 201 odgovora)	Težina pitanja
1	61	0,41
2	43	0,39
3	23	0,11
4	78	0,21
5	82	0,30
Prosječna težina pitanja:		0,29
Standardna devijacija:		0,12

Prosječna težina pitanja **zatvorenog tipa** bila je **0,44**, dok je prosječna težina pitanja kod **otvorenog tipa** bila **0,29** što je bilo i očekivano zbog mjerenja viših ishoda učenja iz područja programiranja. Bitno je napomenuti da što je vrijednost pitanja bliža 1, to je pitanje lakše.



Raspon težine	Pojavnost pitanja
0.1 do 0.19	5
0.2 do 0.29	3
0.3 do 0.39	2
0.4 do 0.49	3
0.5 do 0.59	5
0.6 do 0.69	5
0.7 do 0.79	2
0.8 do 0.89	3
0.9 do 0.99	2

Slika 47. Analiza težine pitanja iz *pretesta* koji je korišten u *prvom glavnom istraživanju*



Raspon težine	Pojavnost pitanja
0,1 do 0,19	3
0,2 do 0,29	4
0,3 do 0,39	5
0,4 do 0,49	10
0,5 do 0,59	5
0,6 do 0,69	1
0,7 do 0,79	2

Slika 48. Analiza težine pitanja iz *posttesta* koji je korišten u *prvom glavnom istraživanju*

6.2.3. Analiza rezultata anketnog upitnika u provedenom prvom glavnom istraživanju

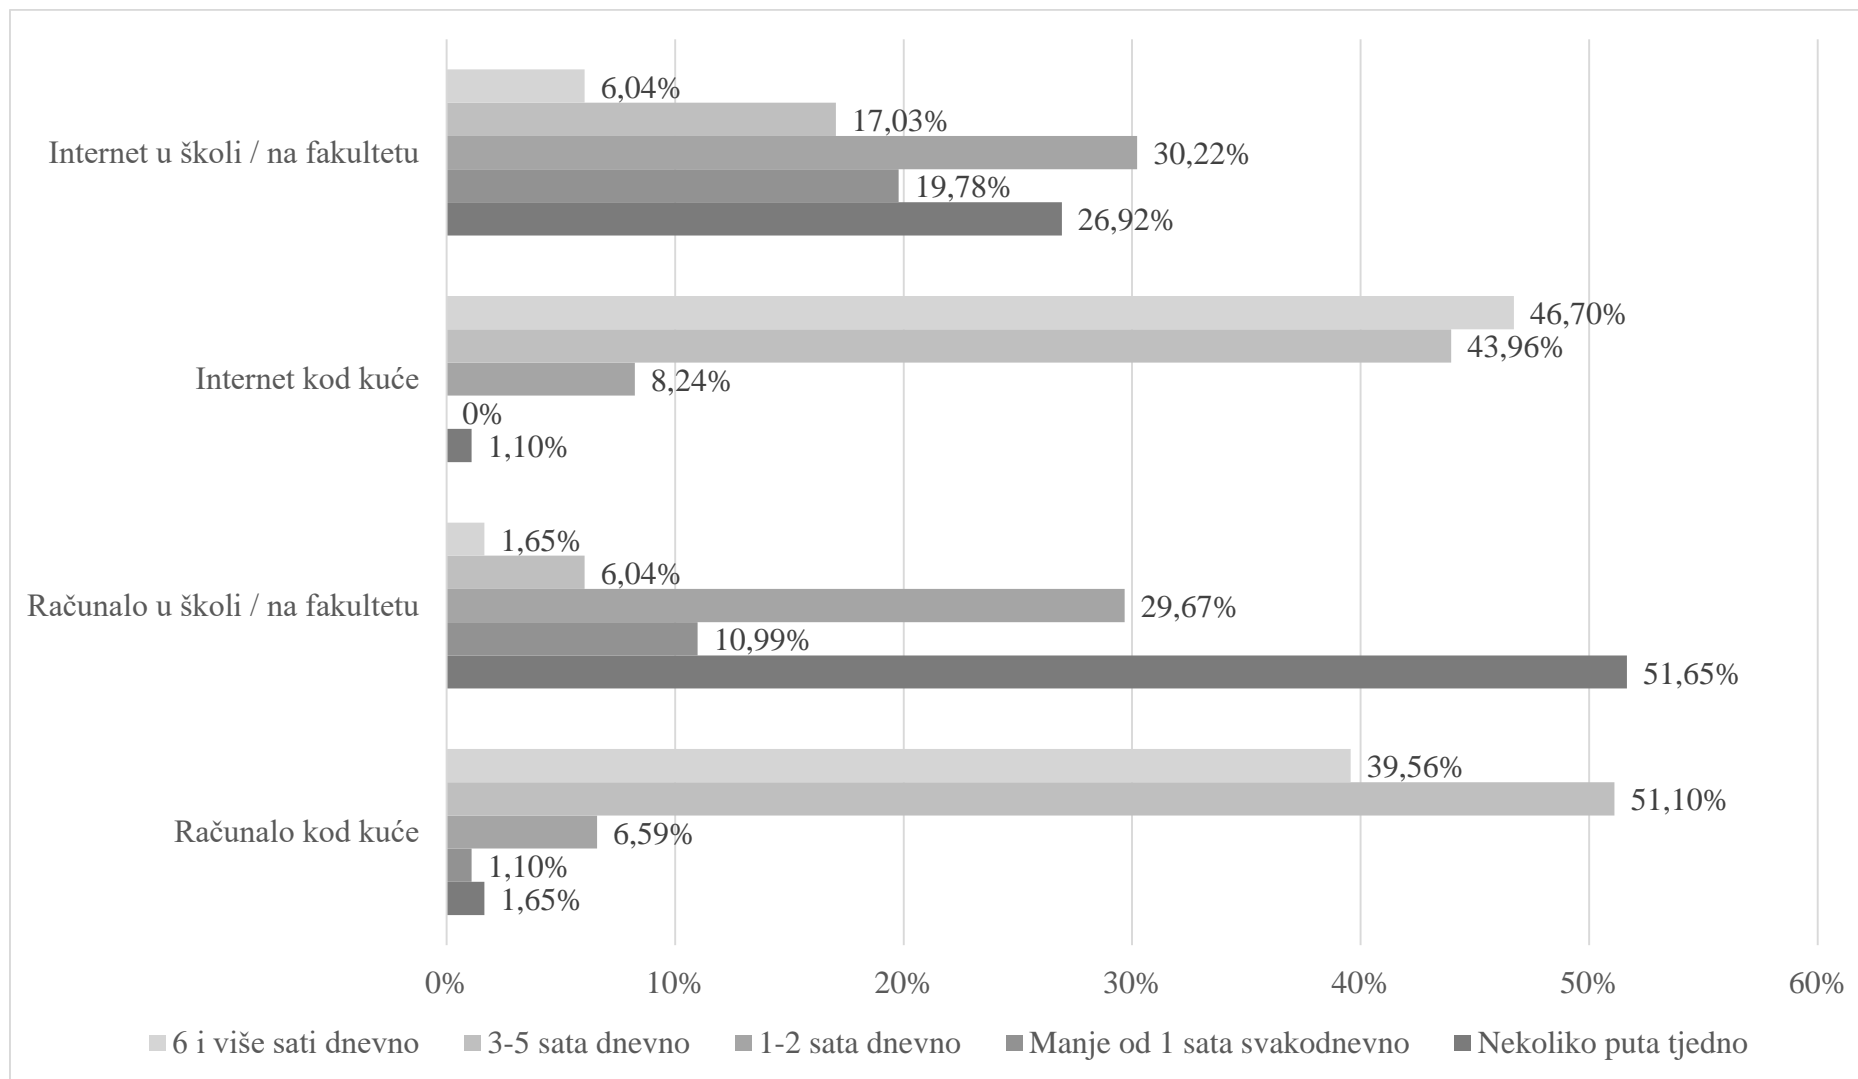
Anketni upitnik u provedenom prvom glavnom istraživanju valjano je ispunilo **182 ispitanika** od ukupno 201 polaznika e-tečaja. Rezultat dobne raspodjele ispitanika prikazan je u tablici 97. U nastavku poglavlja navode se deskriptivni pokazatelji za **prvu cjelinu anketnog upitnika** pod nazivom "*Osobni podaci*". **Prva cjelina anketnog upitnika** sastoji se od **tri skale** koje se navode u nastavku rada. Cronbach alpha koeficijent za prve tri skale iznosi ,595 uz broj čestica koji iznosi 12.

Tablica 97. Analiza odgovora svih ispitanika u provedenom *prvom glavnom istraživanju* prema učestalosti korištenja računala i Internet tehnologije (N=182)

	Računalo kod kuće		Računalo u školi / na fakultetu		Internet kod kuće		Internet u školi / na fakultetu	
	Frekv.	%	Frekv.	%	Frekv.	%	Frekv.	%
Nekoliko puta tjedno	3	2%	94	51%	2	1%	49	27%
Manje od 1 sata svakodnevno	2	1%	20	11%	0	0 %	36	20%
1-2 sata dnevno	12	6%	54	31%	15	8%	55	30%
3-5 sata dnevno	93	52%	11	6%	80	44%	31	17%
6 i više sati dnevno	72	39%	3	1%	85	47%	11	6%
Ukupno	182	100 %	182	100 %	182	100 %	182	100%

Frekv. = frekvencija odgovora

Iz tablice 97. može se zaključiti kako ispitanici **kod kuće** koriste računalo **tri do pet sati** dnevno, te Internet **šest i više sati** dnevno. Ispitanici **na fakultetu** računalo koriste **nekoliko puta tjedno**, a Internet koriste **jedan do dva sata** dnevno. U nastavku rada prikazana je analiza odgovora svih ispitanika u provedenom *prvom glavnom istraživanju* i to prema **učestalosti korištenja računala i Internet tehnologije**.



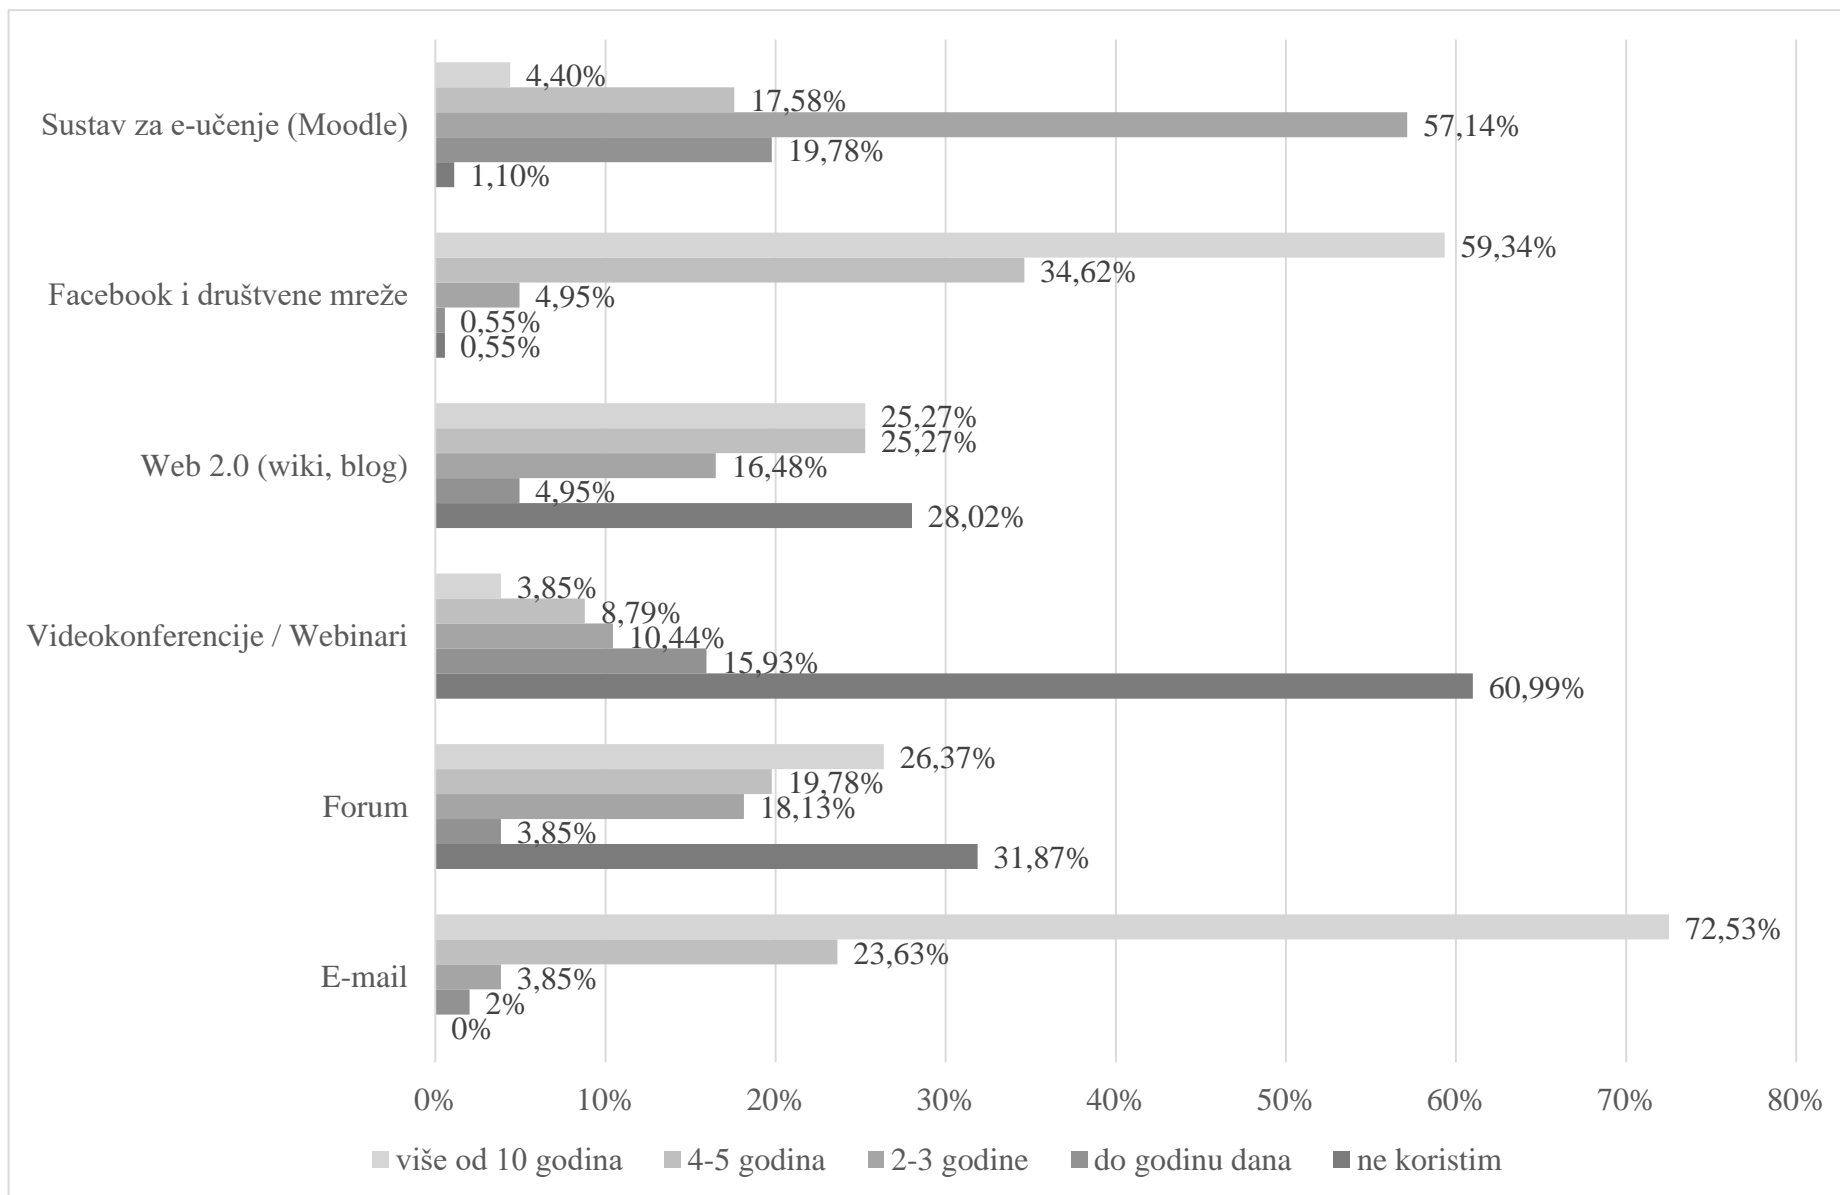
Slika 49. Grafički prikaz analize odgovora svih ispitanika u provedenom *prvom glavnom istraživanju* prema učestalosti korištenja računala i Internet tehnologije (N=182; uključuje *eksperimentalnu* i *kontrolnu* skupinu ispitanika)

Tablica 98. Analiza odgovora svih ispitanika u provedenom *prvom glavnom istraživanju* s obzirom na **dužinu korištenja** (u godinama) **Internet tehnologije** (N=182)

	E-mail		Forum		Videokonferencije / Webinari		Web 2.0 (wiki, blog)		Facebook i društvene mreže		Sustav za e-učenje (Moodle)	
	f	%	f	%	f	%	f	%	f	%	f	%
Ne koristim	0	0%	58	32%	111	61%	51	28%	1	1%	2	1%
Do godinu dana	0	2%	7	5%	29	16%	9	5%	1	1%	36	20%
2-3 godine	7	3%	33	18%	19	10%	3	17%	9	5%	104	57%
4-5 godina	43	23%	36	19%	16	9%	46	25%	63	34%	32	18%
Više od 10 godina	132	72%	48	26%	7	4%	46	25%	108	59%	8	4%
Ukupno	182	100%	182	100%	182	100%	182	100%	182	100%	182	100%

f = frekvencija odgovora

Iz tablice 98. može se zaključiti kako ispitanici u provedenom *prvom glavnom istraživanju* koriste **e-mail** i **društvene mreže** više od 10 godina. **Forum**, **videokonferencije** i **webinare** ne koriste uopće, dok **web 2.0 alate** koriste četiri i više godina. Ispitanici koriste **sustave za e-učenje** poput Moodle-a praktički od početka studiranja, otprilike dvije do tri godine. Zanimljivo je kako su prosječni odgovori ispitanika *prvog glavnog istraživanja* identični prosječnim odgovorima ispitanika *predistraživanja*. U nastavku rada prikazana je analiza odgovora svih ispitanika u provedenom *prvom glavnom istraživanju* prema **učestalosti korištenja računala i Internet tehnologije**.

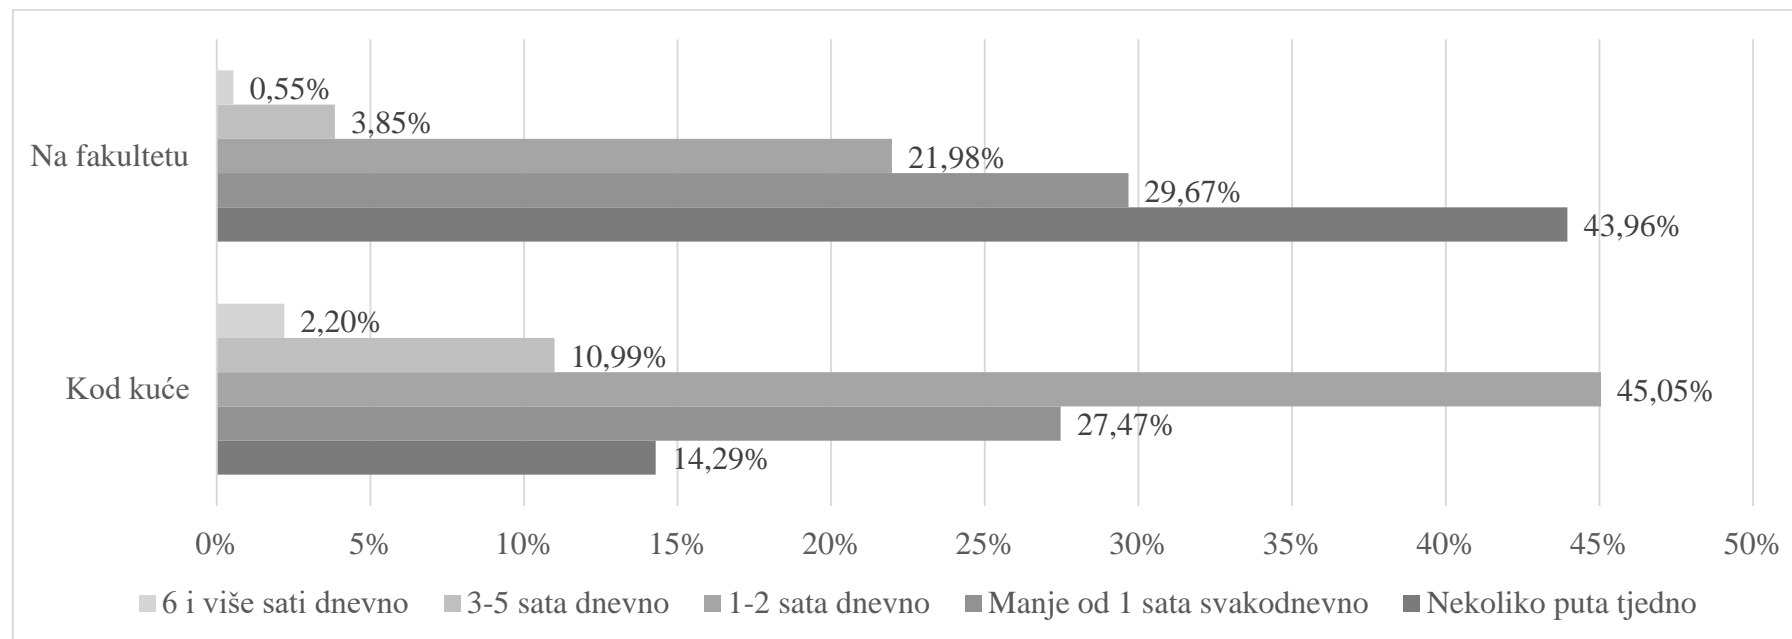


Slika 50. Grafički prikaz analize odgovora svih ispitanika u provedenom *prvom glavnom istraživanju* s obzirom na **dužinu korištenja** (u godinama) **Internet tehnologije** (N=182; uključuje *eksperimentalnu* i *kontrolnu* skupinu ispitanika)

Tablica 99. Analiza odgovora svih ispitanika u provedenom *prvom glavnom istraživanju* s obzirom na korištenje tehnologije e-učenja (N=182)

	Kod kuće		Na fakultetu	
	Frekv.	%	Frekv.	%
Nekoliko puta tjedno	26	14,29 %	80	43,96 %
Manje od 1 sata svakodnevno	50	27,47 %	54	29,67 %
1-2 sata dnevno	82	45,05 %	40	21,98 %
3-5 sata dnevno	20	10,99 %	7	3,85 %
6 i više sati dnevno	4	2,20 %	1	0,55 %
Ukupno	182	100 %	182	100 %

Frekv. = frekvencija odgovora



Slika 51. Grafički prikaz analize odgovora svih ispitanika u provedenom *prvom glavnom istraživanju* s obzirom na korištenje tehnologije e-učenja (N=182; uključuje *eksperimentalnu* i *kontrolnu* skupinu ispitanika)

U tablici 100. navodi se analiza rezultata za **drugu cjelinu anketnog upitnika**. Obuhvaćene su sljedeće skale: *Zadovoljstvo korištenja e-tečaja*, *Pregled nad tečajem / navigacija*, *Povratne informacije u e-tečaju*, *Zaokupljenost / uživljanje*, *Priprema / uputa za rad s e-tečajem*, *Primjerena težina e-tečaja*, *Motivacijski poticaji*, *Agregacija elemenata za motivacijske poticaje*, *Interakcija unutar e-tečaja*, *Postignuće učenja*, *Individualni proces učenja*, *Doživljaj e-tečaja*, *Evaluacija e-tečaja*. Analiza druge cjeline navodi se u tablici 100. i detaljnije u **prilogu 6.** ove doktorske disertacije. Treća cjelina prikazana je u tablicama 101. i 102.

Tablica 100. Analiza skala **druge cjeline anketnog upitnika** u provedenom *prvom glavnom istraživanju* prije isključivanja neodgovarajućih čestica iz skala (N=182)

Naziv skale	Broj čestica	Prosječna vrijednost	Standardna devijacija	Raspon odgovora	Cronbach alpha koef.
Zadovoljstvo korištenja e-tečaja	9	2,95	1,10	1-5	,858
Pregled nad tečajem / navigacija	11	3,14	1,21	1-5	,903
Povratne informacije u e-tečaju	4	3,41	1,16	1-5	,904
Zaokupljenost / uživljanje	13	2,84	1,10	1-5	,841
Priprema / uputa za rad s e-tečajem	7	3,19	1,22	1-5	,739
Primjerena težina e-tečaja	8	3,16	1,16	1-5	,770
Motivacijski poticaji	4	3,27	1,03	1-5	,835
Agregacija elemenata za motivacijske poticaje	18	4,19	1,91	1-7	,949
Interakcija unutar e-tečaja	10	3,00	1,12	1-5	,885
Postignuće učenja	9	3,48	0,94	1-5	,867
Individualni proces učenja	7	3,64	1,06	1-5	,859
Doživljaj e-tečaja	10	3,33	1,12	1-5	,778
Evaluacija e-tečaja	28	3,14	1,27	1-5	,931

U tablici 101. i 102. navodi se analiza rezultata za **treću cjelinu anketnog upitnika**. Obuhvaćena je skala pod nazivom *Evaluacija elemenata računalnih igara* koja se sastoji od 41 pitanja. Prvih 19 pitanja odnosi se na općenitu procjenu **mišljenja** ispitanika, dok se drugi dio od 22 pitanja odnosi na utjecaj motivacijskih elemenata iz računalnih igara na učenje ispitanika.

Tablica 101. Analiza čestica **treće cjeline** *anketnog upitnika* (za čestice od 1 do 19) koja se odnosi na procjenu **mišljenja** ispitanika u provedenom *prvom glavnom istraživanju* (N=182)

Red. broj	Tvrdnja	Prosječna vrijednost	Standardna devijacija σ	Raspon odgovora
1	Bolje sam motiviran/a uz ljepše dizajnirano korisničko sučelje.	4,15	1,00	1-5
2	Zabavno mi je sakupljati bodove za svoja postignuća.	4,16	1,05	1-5
3	Trenutno stanje vlastitog postignuća treba biti jasno vidljivo.	4,08	1,02	1-5
4	Trenutna povratna informacija mi je poželjna.	4,20	0,85	2-5
5	Zabavno mi je otkriti sve što se, u sustavu za učenje, otkriti može.	3,99	0,90	1-5
6	Bolje pamtim kroz igru.	4,20	1,00	1-5
7	Zabavno mi je istraživati granice sustava za učenje.	3,75	1,14	1-5
8	Preferiram dinamičan sustav za učenje.	4,03	0,88	2-5
9	Preferiram jednostavno korisničko sučelje.	3,62	1,11	1-5
10	Preferiram biti vođen/a kroz sustav za učenje.	3,53	1,00	1-5
11	Stres negativno utječe na moj interes za temom.	3,92	1,17	1-5
12	Preferiram statičan oblik nastavnih sadržaja.	2,47	1,03	1-5
13	Preferiram surađivati s drugim studentima kroz timski rad.	3,20	1,22	1-5
14	Preferiram dijeliti znanje i pomagati drugima studentima.	3,80	1,08	1-5
15	Zabavno mi je natjecati se s drugim studentima.	3,47	1,21	1-5
16	Volim igrati računalne igre u slobodno vrijeme.	3,87	1,40	1-5
17	Volim igrati edukacijske računalne igre.	3,41	1,30	1-5
18	Preferiram se uspoređivati s boljim studentima.	3,20	1,285	1-5
19	Volim osjećaj svojeg napretka kroz sustav.	4,01	1,043	1-5

Tablica 102. Analiza čestica **treće cjeline** *anketnog upitnika* (za čestice od 20 do 41) koja se odnosi na **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika u provedenom *prvom glavnom istraživanju* (N=182)

Red. broj	U kolikoj mjeri smatrate da...	Prosječna vrijednost	Standardna devijacija σ	Raspon odgovora
20	... priča pomaže u boljem razumijevanju ciljeva učenja?	4,10	0,88	1-5
21	... individualni zadaci pomažu motiviranju studenata?	3,81	0,90	1-5
22	... individualni zadaci podižu interes za učenjem kod studenata?	3,74	0,91	1-5
23	... postepeno otkrivanje sadržaja pozitivno utječe na interes za temu?	3,87	0,94	1-5
24	... međusobna suradnja pozitivno utječe na Vaše učenje?	3,74	1,01	1-5
25	... natjecanje pozitivno utječe na Vaše učenje?	3,44	1,16	1-5
26	... vizualan dizajn pozitivno utječe na Vaše učenje?	4,03	0,91	1-5
27	... jednostavno grafičko sučelje pozitivno utječe na Vaše učenje?	3,74	1,00	1-5
28	... ambijent u sustavu pozitivno utječe na Vaše učenje?	3,90	0,88	1-5
29	... resursi u sustavu pozitivno utječu na Vaše učenje?	3,98	0,80	2-5
30	... pokazatelj preostalog vremena pozitivno utječe na Vaše učenje?	2,85	1,29	1-5
31	... nagrađivanje za postignuća pozitivno utječe na Vaše učenje?	4,09	0,98	1-5
32	... sakupljanje bodova pozitivno utječe na Vaše učenje?	4,01	1,01	1-5
33	... dodjela bedževa pozitivno utječe na Vaše učenje?	3,62	1,21	1-5
34	... dodjela certifikata pozitivno utječe na Vaše učenje?	4,03	1,07	1-5
35	... različite razine težine pozitivno utječe na Vaše učenje?	3,93	0,85	1-5
36	... trenutna povratna informacija pozitivno utječe na Vaše učenje?	4,07	0,84	1-5
37	... "Top 10" lista najboljih pozitivno utječe na Vaše učenje?	3,29	1,38	1-5
38	... evidencija aktivnosti pozitivno utječe na Vaše učenje?	3,49	1,14	1-5
39	... slobodan odabir materijala pozitivno utječe na Vaše učenje?	4,07	0,86	1-5
40	... raznolikost sadržaja pozitivno utječe na Vaše učenje?	4,11	0,88	1-5
41	... interaktivni materijali pozitivno utječu na Vaše učenje?	4,11	0,86	1-5

Tablica 103. Analiza rezultata *eksperimentalne* i *kontrolne* grupe u provedenom *prvom glavnom istraživanju* prije isključivanja neodgovarajućih čestica (N=182)

Naziv skale	Broj čestica	Cronbach alpha koef.	M _E	M _K	σ _E	σ _K	t	p
Zadovoljstvo korištenja e-tečaja	9	,858	3,05	2,86	1,14	1,05	3,59	0,0003
Pregled nad tečajem / navigacija	11	,903	3,19	3,09	1,23	1,19	1,76	0,0779
Povratne informacije u e-tečaju	4	,904	3,98	2,89	0,84	1,17	14,26	0,0001
Zaokupljenost / uživanje	13	,841	2,99	2,71	1,06	1,13	6,22	0,0001
Priprema / uputa za rad s e-tečajem	7	,739	3,36	3,04	1,22	1,20	4,69	0,0001
Primjerena težina e-tečaja	8	,770	3,20	3,13	1,19	1,14	0,99	0,3193
Motivacijski poticaji	4	,835	3,54	3,02	0,97	1,02	6,98	0,0001
Agregacija elemenata za motivacijske poticaje	18	,949	4,63	3,79	1,79	1,93	12,77	0,0001
Interakcija unutar e-tečaja	10	,885	3,24	2,77	1,02	1,16	9,21	0,0001
Postignuće učenja	9	,867	3,64	3,34	0,83	1,00	6,52	0,0001
Individualni proces učenja	7	,859	3,90	3,00	0,91	1,12	15,64	0,0001
Doživljaj e-tečaja	10	,778	3,42	3,25	1,17	1,07	3,11	0,0019
Evaluacija e-tečaja	28	,931	3,29	3,01	1,13	1,10	8,98	0,0001

M = prosječna vrijednost, σ = standardna devijacija, E = *eksperimentalna*, K = *kontrolna* grupa
t = odnos između prosječnih vrijednosti *eksperimentalne* i *kontrolne* grupe, te standardne pogreške razlike.

p = signifikantnost, tj. što je p vrijednost manja to je manja i empirijski utvrđena vjerojatnost odbacivanja istinite hipoteze i obratno. Precrtane p vrijednosti nisu statistički značajne.

6.2.4. Rasprava o rezultatima obrade podataka u *prvom glavnom istraživanju*

U ovom potpoglavlju prikazuju se rezultati *prvog glavnog istraživanja* koje je provedeno nad ispitanicima **Fakulteta organizacije i informatike**, koji su pohađali kolegij "Programiranje 2" i dobrovoljno sudjelovali u istraživanju. **Ukupan broj** ispitanika bio je **201** koji su prema evidenciji na vježbama podijeljeni u 14 grupa po 15 studenata. *Eksperimentalne* grupe bile su: **G2, G3, G5, G7, G11, G12, G14**. *Kontrolne* grupe bile su: **G1, G4, G6, G8, G9, G10, G13**. *Predtest* provjeru znanja u potpunosti je ispunio 201 ispitanik, dok je *posttest* ispunilo 192 ispitanika. *Anketni upitnik* u cijelosti je ispunilo **182** ispitanika.

6.2.4.1. *Predtest* analiza rezultata u provedenom *prvom glavnom istraživanju*

Predtest je sadržavao jedno pitanje manje u odnosu na *predistraživanje*, te tako broji ukupno 30 pitanja (25 pitanja s 4 ponuđena odgovora i 5 pitanja s prostorom za vlastoručno upisivanje odgovora). Pitanja su obuhvaćala općenite pojmove iz područja programiranja, poput pitanja o naredbama programa C++, varijablama, logičkim operatorima i sl. Primjer pitanja iz *predtesta* kolegija "Programiranje 2" nalazi se u prilogu 2. ove doktorske disertacije (**Slika G**).

Pojedinačne vrijednosti i testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta* međusobnih parova, navedene su se ranije u ovom poglavlju između sljedećih parova: **G2 i G8, G3 i G9, G5 i G13, G7 i G4, G11 i G10, G12 i G1, G14 i G6**. U nastavku se navode skupni rezultati *predtesta* za sve ispitanike *prvog glavnog istraživanja*. Prosječna vrijednost bodova za **sve ispitanike eksperimentalne** ($G_E = G2, G3, G5, G7, G11, G12, G14$) grupe (N=99) iznosi 15,57 uz standardnu devijaciju od 4,17. Prosječna vrijednost bodova za **sve ispitanike kontrolne** ($G_K = G1, G4, G6, G8, G9, G10, G13$) grupe (N=102) iznosi 15,25 uz standardnu devijaciju od 3,72 i najčešću (Mod) vrijednost sakupljenih bodova od 14.

Posljednja provjera je provedena nad svim ispitanicima *eksperimentalne* (G_E) grupe (N=99) i *kontrolne* (G_K) grupe (N=102). Iz tablice 80., koja je prikazana unutar poglavlja 6.2.1., može se zaključiti kako između svih ispitanika *eksperimentalne* (G_E) grupe, te svih ispitanika *kontrolne* (G_K) grupe, **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*. Na temelju rezultata *predtesta* zaključuje se kako se grupe statistički značajno ne razlikuju, te se ukazuje na mogućnost dolaska do statistički značajnih razlika u *eksperimentalnom* sustavu. *Eksperimentalna* grupa izložena je *eksperimentalnom* e-tečaju, *kontrolna* je izložena klasičnom e-tečaju, te se nastavni sadržaji međusobno ne razlikuju.

6.2.4.2. Posttest analiza rezultata u provedenom prvom glavnom istraživanju

Posttest je sadržavao ukupno 30 pitanja. Struktura pitanja ista je kao i u ranije provedenom predtestu. Pitanja su obuhvaćala specifične pojmove iz područja programiranja, koja su navedena unutar poglavlja 5.3.3. i u prilogu 2. ove disertacije (Slika H). U nastavku teksta navode se skupni rezultati predtesta za sve ispitanike prvog glavnog istraživanja.

Prosječna vrijednost bodova za sve ispitanike eksperimentalne ($G_E = G_2, G_3, G_5, G_7, G_{11}, G_{12}, G_{14}$) grupe ($N=96$) iznosi 13,89 bodova, uz standardnu devijaciju od 5,42 i Mod vrijednost od 9. Prosječna vrijednost bodova za sve ispitanike kontrolne ($G_K = G_1, G_4, G_6, G_8, G_9, G_{10}, G_{13}$) grupe ($N=96$) iznosi 12,03 bodova, uz standardnu devijaciju od 4,05 i najčešću (Mod) vrijednost sakupljenih bodova od 11.

Testiranje statističke značajnosti razlike metodom t-testa između rezultata posttesta svih ispitanika eksperimentalne (G_E) grupe ($N=96$) i kontrolne (G_K) grupe ($N=96$) prikazana je unutar poglavlja 6.2.2. Tablica 92. prikazuje izračun statističke značajnosti temeljem rezultata predtesta za provjeru znanja, u kojoj izračunata p vrijednost iznosi 0,007. Iz navedenog se može zaključiti, uz mogućnost pogreške od 1%, kako između svih ispitanika eksperimentalne (G_E) grupe te svih ispitanika kontrolne (G_K) grupe postoji statistički značajna razlika s obzirom na prosječne rezultate posttesta. Eksperimentalna grupa postigla je bolji rezultat za 15,46%.

6.2.4.3. Unutarnja konzistentnost skala u provedenom prvom glavnom istraživanju

U ovom potpoglavlju nalazi se analiza unutarnje konzistentnosti skala iz provedenog prvog glavnog istraživanja koje je prikazano i u prilogu 6. Rezultat analize unutarnje konzistentnosti skala kao i pregled isključenih čestica moguće je vidjeti u tablicama 104. i 105.

Tablica 104. Pregled isključenih čestica iz skala i daljnje obrade u provedenom prvom glavnom istraživanju ($N=182$)

Naziv skale	Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach alpha ako se čestica izbaci
Zaokupljenost / uživljanje	UZI_2R	,096	,856
Priprema / uputa za rad s e-tečajem	UPT_5R	,209	,767
Primjerena težina e-tečaja	TEZ_5	,285	,782
Interakcija unutar e-tečaja	INT_11R	-,074	,919
Doživljaj e-tečaja	DOZ_6R	,115	,810

Nakon isključivanja neodgovarajućih čestica anketni upitnik u drugom dijelu broji 133 česticu. Kompletan analiza i opis unutarnje konzistentnosti nalazi se u prilogu 6.

Tablica 105. Usporedni prikaz analize anketnog upitnika prije i nakon isključivanja neodgovarajućih čestica iz skala (N=182)

Naziv skale	Analiza anketnog upitnika <u>prije</u> isključivanja neodgovarajućih čestica iz skala (N=182)				Analiza anketnog upitnika <u>nakon</u> isključivanja neodgovarajućih čestica iz skala (N=182)			
	Broj čestica	Prosječna vrijednost	Standardna devijacija σ	Cronbach alpha koef.	Broj čestica	Prosječna vrijednost	Standardna devijacija σ	Cronbach alpha koef.
Zadovoljstvo korištenja e-tečaja	9	2,95	1,10	,858	9	2,95	1,10	,858
Pregled nad tečajem / navigacija	11	3,14	1,21	,903	11	3,14	1,21	,903
Povratne informacije u e-tečaju	4	3,41	1,16	,904	4	3,41	1,16	,904
Zaokupljenost / uživanje	13	2,84	1,10	,841	12	2,81	1,10	,856
Priprema / uputa za rad s e-tečajem	7	3,19	1,22	,739	6	3,36	1,16	,767
Primjerena težina e-tečaja	8	3,16	1,16	,770	7	3,13	1,17	,782
Motivacijski poticaji	4	3,27	1,03	,835	4	3,27	1,03	,835
Agregacija elemenata za motivacijske poticaje	18	4,19	1,91	,949	18	4,19	1,91	,949
Interakcija unutar e-tečaja	10	3,00	1,12	,885	9	3,02	1,12	,919
Postignuće učenja	9	3,48	0,94	,867	9	3,48	0,94	,867
Individualni proces učenja	7	3,64	1,06	,859	7	3,64	1,06	,859
Doživljaj e-tečaja	10	3,33	1,12	,778	9	3,31	1,11	,810
Evaluacija e-tečaja	28	3,14	1,27	,931	28	3,29	1,12	,931

6.2.4.4. Razlika *eksperimentalne* i *kontrolne* skupine u odnosu na rezultate primjenom skala za procjenu

Tablica 106. Analiza rezultata *eksperimentalne* i *kontrolne* grupe u provedenom *prvom glavnom istraživanju* nakon korekcije svih skala (N=182)

Naziv skale	Broj čestica	Cronbach alpha koef.	M _E	M _K	σ _E	σ _K	t	p
Zadovoljstvo korištenja e-tečaja	9	,858	3,05	2,86	1,14	1,05	3,59	0,0003
Pregled nad tečajem / navigacija	11	,903	3,19	3,09	1,23	1,19	1,76	0,0779
Povratne informacije u e-tečaju	4	,904	3,98	2,89	0,84	1,17	14,26	0,0001
Zaokupljenost / uživanje	12	,856	2,97	2,67	1,07	1,11	6,36	0,0001
Priprema / uputa za rad s e-tečajem	6	,767	3,54	3,20	1,13	1,16	4,92	0,0001
Primjerena težina e-tečaja	7	,782	3,16	3,10	1,19	1,14	1,03	0,3004
Motivacijski poticaji	4	,835	3,54	3,02	0,97	1,02	6,98	0,0001
Agregacija elemenata za motivacijske poticaje	18	,949	4,63	3,79	1,79	1,93	12,77	0,0001
Interakcija unutar e-tečaja	9	,919	3,31	2,75	1,00	1,16	10,37	0,0001
Postignuće učenja	9	,867	3,64	3,34	0,83	1,00	6,52	0,0001
Individualni proces učenja	7	,859	3,90	3,00	0,91	1,12	15,64	0,0001
Doživljaj e-tečaja	9	,810	3,42	3,21	1,16	1,05	3,80	0,0001
Evaluacija e-tečaja	28	,931	3,29	3,01	1,13	1,10	8,98	0,0001

M = prosječna vrijednost, σ = standardna devijacija, E = *eksperimentalna*, K = *kontrolna* grupa
p = signifikantnost, tj. što je p vrijednost manja to je manja i empirijski utvrđena vjerojatnost odbacivanja istinite hipoteze i obratno. Precrtane p vrijednosti nisu statistički značajne.

Iz tablice 106. vidljivo je kako u skalama *Pregled nad tečajem / navigacija* i *Primjerena težina e-tečaja* ne postoji statistički značajna razlika između *eksperimentalne* i *kontrolne* grupe ispitanika. Skupni odgovori u svim ostalim slučajevima se statistički značajno razlikuju. Analiza čestica **treće cjeline** prikazane su u tablicama 107. i 108.

Tablica 107. Analiza čestica **treće cjeline** *anketnog upitnika* (za čestice od 1 do 19) koja se odnosi na procjenu **mišljenja** ispitanika u provedenom *prvom glavnom istraživanju* (N=182)

Red. broj	Tvrdnja	M _E	M _K	σ _E	σ _K	t	p
1	Bolje sam motiviran/a uz ljepše dizajnirano korisničko sučelje.	4,17	4,14	1,00	1,02	0,23	0,8127
2	Zabavno mi je sakupljati bodove za svoja postignuća.	4,22	4,12	1,00	1,11	0,65	0,5154
3	Trenutno stanje vlastitog postignuća treba biti jasno vidljivo.	4,10	4,05	1,03	1,01	0,33	0,7385
4	Trenutna povratna informacija mi je poželjna.	4,26	4,15	0,84	0,86	0,92	0,3564
5	Zabavno mi je otkriti sve što se, u sustavu za učenje, otkriti može.	4,09	4,24	0,87	3,05	0,43	0,6611
6	Bolje pamtim kroz igru.	4,24	4,16	0,98	1,03	0,55	0,5771
7	Zabavno mi je istraživati granice sustava za učenje.	3,92	3,60	1,08	1,19	1,89	0,0601
8	Preferiram dinamičan sustav za učenje.	4,09	3,97	0,87	0,90	0,93	0,3502
9	Preferiram jednostavno korisničko sučelje.	3,67	3,57	1,13	1,11	0,59	0,5542
10	Preferiram biti vođen/a kroz sustav za učenje.	3,64	3,42	0,98	1,02	1,50	0,1343
11	Stres negativno utječe na moj interes za temom.	3,97	3,87	1,17	1,19	0,52	0,5997
12	Preferiram statičan oblik nastavnih sadržaja.	2,48	2,45	1,07	1,01	0,19	0,8449
13	Preferiram surađivati s drugim studentima kroz timski rad.	3,30	3,11	1,26	1,19	1,06	0,2875
14	Preferiram dijeliti znanje i pomagati drugima studentima.	3,80	3,80	1,10	1,08	0,02	0,9773
15	Zabavno mi je natjecati se s drugim studentima.	3,67	3,29	1,19	1,22	2,08	0,0388
16	Volim igrati računalne igre u slobodno vrijeme.	3,68	4,04	1,44	1,34	1,76	0,0798
17	Volim igrati edukacijske računalne igre.	3,38	3,44	1,39	1,23	0,32	0,7467
18	Preferiram se uspoređivati s boljim studentima.	3,32	3,08	1,22	1,33	1,24	0,2136
19	Volim osjećaj svojeg napretka kroz sustav.	3,95	4,05	0,98	1,10	0,63	0,5256

M = prosječna vrijednost, **σ** = standardna devijacija, **E** = *eksperimentalna*, **K** = *kontrolna* grupa
p = signifikantnost, tj. što je p vrijednost manja to je manja i empirijski utvrđena vjerojatnost odbacivanja istinite hipoteze i obratno. Precrtane p vrijednosti nisu statistički značajne.

Tablica 108. Analiza čestica **treće cjeline** anketnog upitnika (za čestice od 20 do 41) koja se odnosi na **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika u provedenom *prvom glavnom istraživanju* (N=182)

Red. broj	U kolikoj mjeri smatrate da...	M _E	M _K	σ _E	σ _K	t	p
20	... priča pomaže u boljem razumijevanju ciljeva učenja?	4,05	4,16	0,94	0,84	0,84	0,3977
21	... individualni zadaci pomažu motiviranju studenata?	3,89	3,75	0,93	0,87	1,02	0,3056
22	... individualni zadaci podižu interes za učenjem kod studenata?	3,85	3,64	0,92	0,91	1,53	0,1267
23	... postepeno otkrivanje sadržaja pozitivno utječe na interes za temu?	3,98	3,77	0,88	0,99	1,49	0,1363
24	... međusobna suradnja pozitivno utječe na Vaše učenje?	3,80	3,68	1,03	1,00	0,79	0,4261
25	... natjecanje pozitivno utječe na Vaše učenje?	3,69	3,21	1,04	1,23	2,82	0,0052
26	... vizualan dizajn pozitivno utječe na Vaše učenje?	4,01	4,04	0,98	0,86	0,22	0,8231
27	... jednostavno grafičko sučelje pozitivno utječe na Vaše učenje?	3,86	3,63	0,98	1,01	1,56	0,1205
28	... ambijent u sustavu pozitivno utječe na Vaše učenje?	3,92	3,63	0,88	1,01	2,04	0,0426
29	... resursi u sustavu pozitivno utječu na Vaše učenje?	4,03	3,93	0,77	0,84	0,90	0,3679
30	... pokazatelj preostalog vremena pozitivno utječe na Vaše učenje?	2,94	2,77	1,31	1,27	0,90	0,3644
31	... nagrađivanje za postignuća pozitivno utječe na Vaše učenje?	4,15	4,04	0,96	1,01	0,73	0,4641
32	... sakupljanje bodova pozitivno utječe na Vaše učenje?	4,03	3,99	0,99	1,04	0,29	0,7657
33	... dodjela bedževa pozitivno utječe na Vaše učenje?	3,83	3,42	1,21	1,20	2,27	0,0242
34	... dodjela certifikata pozitivno utječe na Vaše učenje?	4,02	4,03	1,07	1,10	0,05	0,9574
35	... različite razine težine pozitivno utječe na Vaše učenje?	4,06	3,82	0,81	0,87	1,88	0,0611
36	... trenutna povratna informacija pozitivno utječe na Vaše učenje?	4,20	3,95	0,79	0,88	1,99	0,0476
37	... "Top 10" lista najboljih pozitivno utječe na Vaše učenje?	3,48	3,11	1,36	1,38	1,85	0,0653
38	... evidencija aktivnosti pozitivno utječe na Vaše učenje?	3,57	3,41	1,21	1,09	0,96	0,3355
39	... slobodan odabir materijala pozitivno utječe na Vaše učenje?	4,03	4,09	0,88	0,85	0,46	0,6398
40	... raznolikost sadržaja pozitivno utječe na Vaše učenje?	4,14	4,08	0,84	0,93	0,40	0,6837
41	... interaktivni materijali pozitivno utječu na Vaše učenje?	4,10	4,12	0,84	0,89	0,09	0,9233

p = signifikantnost, precrtane p vrijednosti nisu statistički značajne.

Iz priloženih tablica koje analiziraju skalu **trećeg dijela anketnog upitnika** koji se odnosi na procjenu **mišljenja** ispitanika i **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika u provedenom **prvom glavnom istraživanju** (N=182), može se zaključiti kako obje grupe ispitanika (*eksperimentalna* i *kontrolna*) imaju podjednake odgovore. Od ukupno 41 pitanja ili tvrdnji, statistički značajna razlika pronađena je u sljedećih pet čestica: "*Zabavno mi je natjecati se s drugim studentima.*", "*...natjecanje pozitivno utječe na Vaše učenje?*", "*...ambijent u sustavu pozitivno utječe na Vaše učenje?*", "*...dodjela bedževa pozitivno utječe na Vaše učenje?*", "*...trenutna povratna informacija pozitivno utječe na Vaše učenje?*".

Tablica 109. Testiranje **statističke značajnosti razlike** metodom t-testa između prosječnih rezultata odgovora na sve čestice **treće cjeline anketnog upitnika** (N=182)

Ispitanici	Broj čestica	Prosječna vrijednost odgovora M	Standardna devijacija σ	t	p
G_E	41	3,84	0,36	1,34	0,1839
G_K	41	3,72	0,41		

G_E = *eksperimentalna* grupa, **G_K** = *kontrolna* grupa

Tablica 109. prikazuje izračun statističke značajnosti na temelju prosječnih rezultata odgovora na čestice **treće cjeline anketnog upitnika** (za čestice od 1 do 41), prema kojoj se može zaključiti kako između *eksperimentalne* (**G_E**) i *kontrolne* (**G_K**) grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate upitnika. Eksperiment niti u ovom slučaju nije utjecao na mišljenje ispitanika *eksperimentalne* grupe. Prosječna vrijednost odgovora obje grupe prelazi vrijednost 3,70 od maksimalne vrijednosti 5, prema kojoj se može zaključiti kako ispitanici imaju pozitivan stav o **motivacijskim elementima** iz računalnih igara.

6.2.4.5. Zaključci imajući u vidu hipoteze i rezultate *prvog glavnog istraživanja*

Prva hipoteza ove disertacije glasi:

H1. E-tečaj dizajniran uz primjenu elemenata računalnih igara **pozitivno utječe na zainteresiranost** polaznika tog tečaja u odnosu na tečaj istog obrazovnog sadržaja, ali bez prisutnosti elemenata računalnih igara.

Kako bi se potvrdila hipoteza H1, provedeno je *prvo glavno istraživanje* u kojemu je prisustvovalo 182 ispitanika. Mišljenje je prikupljeno putem anketnog upitnika koji se sastoji od tri dijela. Prvi dio se odnosi na **deskriptivne pokazatelje** grupe ispitanika, drugi dio na **zadovoljstvo, motivaciju, interakciju i proces učenja**, a treći dio odnosi se na zainteresiranost i općenitu procjenu **mišljenja i utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika

Tvrđnja hipoteze H1 je potvrđena. Odluka se temelji na odgovorima iz *anketnog upitnika* i temeljem objektivnih pokazatelja studentskih aktivnosti unutar Moodle e-tečaja.

Nakon izbacivanja neodgovarajućih čestica iz drugog dijela, *anketni upitnik* broji 133 čestice koje su podijeljene u 13 skala. Iz analize skala može se zaključiti kako *eksperimentalna* grupa u odnosu na *kontrolnu* grupu ispitanika ima veće prosječne vrijednosti odgovora. Izrazita statistička značajnost ne postoji u skalama **Pregled nad tečajem / navigacija** i **Primjerena težina e-tečaja**, za razliku od *predistraživanja* gdje statistička značajnost ne postoji samo u skali **Primjerena težina e-tečaja**.

Tablica 110. Testiranje **statističke značajnosti razlike** metodom t-testa između prosječnih rezultata odgovora **druge cjeline** nakon korekcije *anketnog upitnika* (N=182)

Ispitanici	Broj ispitanika	Broj skala	Prosječna vrijednost odgovora M	Standardna devijacija σ	t	p
G_E	87	13	3,51	0,45	2,94	0,0071
G_K	95	13	3,07	0,28		

G_E = *eksperimentalna* grupa, **G_K** = *kontrolna* grupa

Tablica 110. prikazuje izračun statističke značajnosti na temelju prosječnih rezultata odgovora **druge cjeline** *anketnog upitnika*. Druga cjelina broji 13 skala čije su prosječne vrijednosti temeljene na 133 čestica. Izračunata p vrijednost navodi mogući zaključak, uz mogućnost pogreške od 1%, kako između *eksperimentalne* (**G_E**) i *kontrolne* (**G_K**) grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate odgovora svih skala koje se nalaze unutar drugog dijela *anketnog upitnika*. Testiranje je provedeno na uzorku od 182 ispitanika.

Treći dio *anketnog upitnika* sastoji se od jedne skale koja broji 41 česticu. *Anketni upitnik* evidentira **mišljenja** ispitanika i **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika. U *anketnom upitniku*, gdje je raspon mogućih odgovora od 1-5, vidljivo je kako je prosječna vrijednost odgovora za *eksperimentalnu* grupu iznosila 3,84, a za *kontrolnu* grupu 3,72., iz čega se može zaključiti kako ispitanici imaju pozitivan stav o **motivacijskim elementima** iz računalnih igara. Između grupa niti u ovom slučaju ne postoji statistički značajna razlika, što bi značilo kako eksperiment ni u ovom istraživanju nije utjecao na mišljenje polaznika o motivirajućim elementima. **Kontrolna grupa nije** vidjela niti **sudjelovala** u *eksperimentalnom* gemificiranom e-tečaju, te ima **pozitivno mišljenje** o elementima računalnih igara u obrazovnom sustavu, što ide u prilog zaključku disertacije.

U nastavku disertacije navode se izvještaji o studentskim aktivnostima koji su generirani na temelju *log* zapisa iz Moodle sustava, te ujedno predstavljaju i završni dio koji se uzima u obzir prilikom donošenja zaključka o prihvaćanju ili odbacivanju **hipoteze H1** i **podhipoteze H1.1**.

Tablica 111. Izvještaj o aktivnosti *eksperimentalne* (N=88) i *kontrolne* (N=102) grupe polaznika

Naziv aktivnosti (obrazovna tema)	Aktivnost <i>eksperimentalne</i> grupe			Aktivnost <i>kontrolne</i> grupe		
	Ukupno	Prosjek	SD	Ukupno	Prosjek	SD
Check lista	1047	11,90	19,93			
Dobrodošli u sustav	952	10,82	15,02			
Objašnjenje elemenata i načina s radom u e-tečaju	331	3,76	5,53			
Chat - G	458	5,20	6,97			
Ishodi učenja	342	3,89	6,74	41	0,40	0,84
Forum	1214	13,80	19,86	252	2,47	2,38
Popis pojmova	838	9,52	17,01	22	0,22	0,56
Nastavno poglavlje 1a: Hrpa	430	4,89	7,68	184	1,80	1,98
Nastavno poglavlje 2a: Punjenje i Implementacija hrpe pomoću polja	391	4,44	7,22	135	1,32	1,84
Nastavno poglavlje 3a: Brisanje korijena i Implementacija hrpe pomoću cjelobrojnog polja	358	4,07	7,07	94	0,92	1,51
Nastavno poglavlje 4a: Punjenje hrpe	359	4,08	7,53	84	0,82	1,46
Nastavno poglavlje 5a: Uzastopno brisanje korijena hrpe (<i>Heapsort</i>)	354	4,02	7,39	71	0,70	1,25
Interaktivno ponavljanje: +< 1 >+	2026	23,02	58,32			
Interaktivno ponavljanje: Programiranje A	860	9,77	19,59			
Bonus nastavni sadržaj: Stari i novi nazivi standardnih biblioteka jezika C++	301	3,42	6,98	64	0,63	1,21
Povratna informacija: <i>Hidden 'n' Dangerous</i>	273	3,10	5,85			
Nastavno poglavlje 1b: Stog	251	2,85	4,97			
Nastavno poglavlje 2b: Dodavanje (<i>PUSH</i>), očitavanje i brisanje vrha stoga (<i>POP</i>)	236	2,68	5,26	77	0,75	1,31
Nastavno poglavlje 3b: Ispis cijelog i dealokacija stoga	234	2,66	5,16	76	0,75	1,30
Interaktivno ponavljanje: +< 2 >+	1030	11,70	37,81			
Interaktivno ponavljanje: Programiranje B	382	4,34	17,41			
Bonus nastavni sadržaj: Odnos između jezika C i C++	159	1,81	4,30	72	0,71	1,18
Ukupna aktivnost polaznika e-tečaja	12826	6,62		1280	0,96	

Tablica 111. navodi popis aktivnosti koje su namijenjene *prvom glavnom istraživanju* ove disertacije. Prazan prostor koji je vidljiv unutar *kontrolne* grupe, navodi da ispitanici koji su koristili *kontrolni* e-tečaj nisu mogli pristupiti navedenim aktivnostima. Razlog tome je taj što su navedene aktivnosti vezane uz osnovne principe računalnih igara koji su objašnjeni unutar teorijskog dijela ove disertacije. Aktivnost polaznika, koja se prikazuje u zadnjem retku tablice 111., pokazuje ukupan broj pristupa pojedinoj aktivnosti, te za *eksperimentalnu* grupu iznosi **12826**, dok za *kontrolnu* grupu iznosi **1280**. Studenti *eksperimentalne* grupe su nastavnim materijalima prosječno pristupali **6,62** puta, dok su studenti *kontrolne* grupe nastavnim materijalima prosječno pristupali **0,96** puta.

Zapaženo je kako je *eksperimentalna* grupa ispitanika pokazala značajno veći interes za općenitim elementima sustava, kao što su cjeline pod nazivima "*Forum*" i "*Popis pojmova*". U slučaju *prvog glavnog istraživanja*, bonus nastavni materijali bili su uključeni u oba e-tečaja. *Eksperimentalna* grupa ispitanika iznimno je dobro iskoristila elemente za provjeru znanja unutar kojih je vrlo važnu ulogu imala trenutna povratna informacija o korektno riješenim zadacima. Vidljivo je kako je zbirni broj **pristupa nastavnim poglavljima** gotovo jednak broju **pristupa elementima za ponavljanje** znanja koji se vode pod nazivom "*Interaktivno ponavljanje*". Također, kao i u *predistraživanju*, bonus nastavni materijali su više korišteniji od strane *eksperimentalne* grupe ispitanika.

Iz navedenih pokazatelja može se zaključiti kako je *eksperimentalna* grupa imala znatno veću motiviranost, što je vidljivo kroz veću evidentiranu aktivnost unutar Moodle e-tečaja s obzirom na korištenje dostupnih **nastavnih i nenastavnih materijala**, čime se **prihvća tvrdnja hipoteze H1**.

Pretpostavke ranije navedenih autora (poput Chou, 2016.; Lombriser, 2015.; Adeel, 2014.; Kovacova i Vackova, 2015. i dr.) jesu kako elementi računalnih igara pozitivno utječu na motivaciju studenata. U skladu s time, u nastavku ove disertacije prikazat će se rezultati *prvog glavnog istraživanja* koji utječu na potvrđivanje hipoteze **H1.1**.

Prva podhipoteza ove disertacije glasi:

H1.1. Elementi računalnih igara, koji su uključeni u *eksperimentalni* e-tečaj, **pozitivno utječu** na **veće korištenje nastavnih materijala**, u usporedbi s klasičnim e-tečajem koji sadrži identične nastavne materijale, bez prisutnosti elemenata računalnih igara.

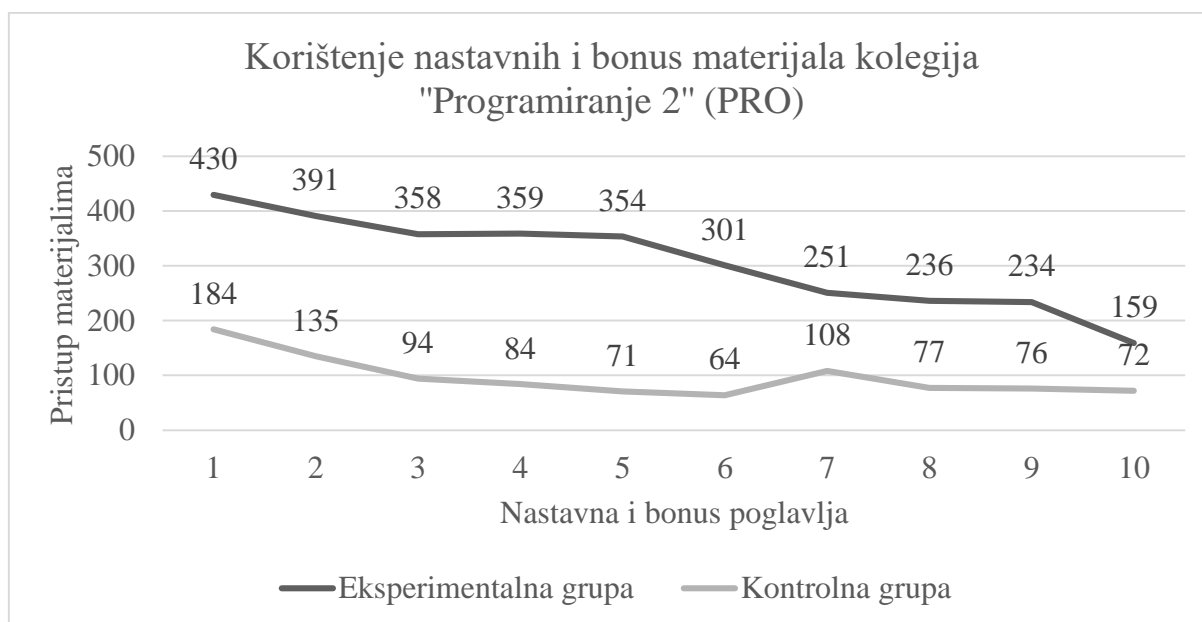
Studenti u okviru kolegija "Programiranje 2", za razliku od studenata koji su bili uključeni u *predistraživanje* ovog doktorskog rada na kolegiju "3D modeliranje", ranije su koristili e-tečaj za potrebe informiranja i pristupanja nastavnim materijalima. Nakon uvodnog predavanja i objašnjenja toka istraživanja, provedena je *predtest* provjera znanja, te su studenti uključeni u *kontrolni* ili *eksperimentalni* e-tečaj s obzirom na prosječan broj bodova pojedine grupe ispitanika. U **poglavlju 5.5.** objašnjeno je kako su studenti jedne grupe na vježbama ujedno i jedna grupa u istraživanju, što znači kako je unutar kolegija "Programiranje 2" postojalo ukupno **14 grupa**, od kojih je sedam bilo *kontrolnih* i sedam *eksperimentalnih*. U provedenom *prvom glavnom istraživanju* unutar kolegija "Programiranje 2", korišteno je ukupno 10 nastavnih i bonus materijala koje su studenti imali na raspolaganju minimalno 14 dana. Izdvojeni nastavni materijali nalaze se u tablici 112. ovog poglavlja.

Tvrđnja podhipoteze H1.1 je potvrđena. Odluka se temelji na tabličnoj i grafičkoj analizi objektivnih pokazatelja koji su generirani pomoću *log* zapisa iz Moodle sustava, te se navode u nastavku ove doktorske disertacije unutar tablice 112. i slike 51.

Tablica 112. Usporedni prikaz korištenja nastavnih i bonus materijala unutar kolegija "PRO"

Nastavna poglavlja kolegija "Programiranje 2"	Eksperimentalna grupa	Kontrolna grupa
1. Nastavno poglavlje 1a: Hrpa	430	184
2. Nastavno poglavlje 2a: Punjenje i Implementacija hrpe pomoću polja	391	135
3. Nastavno poglavlje 3a: Brisanje korijena i Implementacija hrpe pomoću cjelobrojnog polja	358	94
4. Nastavno poglavlje 4a: Punjenje hrpe	359	84
5. Nastavno poglavlje 5a: Uzastopno brisanje korijena hrpe (Heapsort)	354	71
6. Bonus nastavni sadržaj: Stari i novi nazivi standardnih biblioteka jezika C++	301	64
7. Nastavno poglavlje 1b: Stog	251	108
8. Nastavno poglavlje 2b: Dodavanje (PUSH), očitavanje i brisanje vrha stoga (POP)	236	77
9. Nastavno poglavlje 3b: Ispis cijelog i dealokacija stoga	234	76
10. Bonus nastavni sadržaj: Odnos između jezika C i C++	159	72
Ukupna aktivnost nad nastavnim i bonus materijalima	3073	965

Tablica 112. prikazuje usporedni prikaz korištenja nastavnih i bonus materijala koji su generirani na temelju *log* zapisa iz Moodle e-tečaja koji je korišten u *prvom glavnom istraživanju*. Rezultati *log* zapisa u nastavku ovog rada prikazuju se i kroz sliku 52.



Slika 52. Grafički prikaz korištenja nastavnih i bonus materijala u kolegiju "PRO"

- ❖ **Kontrolni** e-tečaj u sebi nije imao ništa osim mogućnosti korištenja *avatara, foruma, te nelinearnog pristupa* navedenim nastavnim materijalima. Tablica 112. i slika 52. prikazuju blago opadanje interesa za nastavnim materijalima do treće teme, nakon koje je interes kod *kontrolne* skupine ispitanika za nastavnim materijalima gotovo konstantan. Izgled e-tečaja koji je vizualno sličan *kontrolnom* e-tečaju iz ovog istraživanja prikazan je na **slici 26**. U provedenom *predistraživanju*, *kontrolni* e-tečaj **prvog glavnog istraživanja** nije uključivao **niti jedan dodatni element** računalnih igara osim već spomenutog avatara, foruma i nelinearnog pristupa sadržajima.
- ❖ **Eksperimentalni** e-tečaj sadrži **elemente računalnih igara** koji su prikazani unutar tablice 26. (poglavlje 4.3.), te su služili kao potpora nastavnim materijalima koji se navode u tablici 112. Studentska aktivnost nad uvodnim poglavljima bilježi najveći odaziv koji se može objasniti **visokim stupnjem interesa** za nastavnim materijalima, isto kao i **visokim stupnjem interesa** za drugačijem pristupu nastavnim sadržajima. Najveća razlika između *kontrolne* i *eksperimentalne* skupine ispitanika uočena je na kraju prve cjeline unutar poglavlja pod nazivom: "*Uzastopno brisanje korijena hrpe (Heapsort)*". Razlika u aktivnosti je gotovo **5 puta** veća u korist *eksperimentalne* skupine ispitanika. Interes za nastavnim materijalima veći je kod *eksperimentalne* grupe ispitanika i u provedenom *predistraživanju*. Objašnjenje ovakvih rezultata pripisuje se vizualno privlačnijem dizajnu e-tečaja, te utjecaju ostalih elemenata računalnih igara koji su navedeni unutar tablice 24.

S obzirom na objektivne rezultate generirane temeljem *log* zapisa o aktivnostima nad nastavnim i bonus materijalima iz Moodle sustava koji je korišten u *prvom glavnom istraživanju*, kao i u slučaju provedenog *predistraživanja*, može se zaključiti kako elementi računalnih igara, koji su uključeni u *eksperimentalni* e-tečaj, **utječu na veće korištenje nastavnih materijala** čime se potvrđuje podhipoteza H1.1 ove doktorske disertacije.

Druga hipoteza ove disertacije glasi:

H2. E-tečaj dizajniran uz primjenu elemenata računalnih igara omogućuje **postizanje boljih rezultata** polaznika u odnosu na tradicionalne pristupe e-učenju, imajući u vidu razinu **stečenog znanja** iz određenog nastavnog sadržaja.

Kako bi se potvrdila hipoteza H2, potrebno je osigurati uvjete za testiranje razine stečenog znanja iz određenog nastavnog sadržaja što je opisano ranije u *predistraživanju*.

- U **prvom koraku** studenti su prema evidenciji na vježbama podijeljeni u 14 grupa. Sedam *eksperimentalnih* grupa su: **G2, G3, G5, G7, G11, G12, G14**. Sedam *kontrolnih* grupa su: **G1, G4, G6, G8, G9, G10, G13**.
- U **drugom koraku** testirana je statistička razlika između grupa. Nakon testiranja **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta* **ispitanika eksperimentalne** (G_E ; $N=99$) i *kontrolne* (G_K ; $N=102$) grupe, utvrđeno je kako **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*, te se ukazuje na mogućnost kako u *eksperimentalnom* programu može doći do statistički značajnih razlika.

Tablica 113. Usporedni prikaz testiranja **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta* i rezultata *posttesta* kod **svih ispitanika eksperimentalne** (G_E ; $N=99$ i 96) i *kontrolne* (G_K ; $N=102$, 96) grupe

Testiranje	Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
<i>Predtest</i>	G_E	99	15,57	4,17	0,57	0,5658
	G_K	102	15,25	3,72		
<i>Posttest</i>	G_E	96	13,89	5,42	2,68	0,0079
	G_K	96	12,03	4,05		

- U **trećem koraku** polaznici oba e-tečaja nastavne su materijale proučavali isključivo kroz e-tečaj. Rezultat je prikazan u tablici 113. Korištenje e-tečaja trajalo je minimalno 14 dana nakon čega slijedi testiranje stečenog znanja primjenom *posttest* provjere znanja.

Provodi se testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta* svih ispitanika *eksperimentalne* (G_E ; $N=96$) i *kontrolne* (G_K ; $N=96$) grupe, gdje izračunata **p vrijednost** iznosi **0,0079** prema kojoj se može zaključiti, uz mogućnost pogreške od 1%, kako između ispitanika *eksperimentalne* grupe te ispitanika *kontrolne* grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*. *Eksperimentalna* grupa postigla je bolji rezultat za **15,46%** čime je **prihvaćena tvrdnja hipoteze H2**.

Druga podhipoteza ove disertacije glasi:

H2.1. *Eksperimentalna* grupa ispitanika, koja je u *predtest* provjeri znanja ostvarila **minimalno 50%** bodova, postići će **statistički značajnije** rezultate u odnosu na *kontrolnu* grupu ispitanika, koja je u *predtest* provjeri znanja ostvarila **minimalno 50%** bodova, s obzirom na ostvarene bodove u *posttest* provjeri znanja.

Za potrebe potvrđivanja podhipoteze H2.1, napravljena je dodatna analiza bodova samo nad ispitanicima koji su zadovoljili dodatni uvjet koji je vezan za ostvarivanje **minimalno 50% ukupnih bodova** u provedenom *predtestu prvog glavnog istraživanja*. Od ukupnog broja ispitanika, njih 118 zadovoljilo je navedeni uvjet. Provedena je analiza *posttest* provjere znanja temeljem ukupno ostvarenih bodova (ukupno 30 pitanja), koja je detaljno prikazana u **poglavljju 6.2.2**. Rezultat skraćene analize nalazi se u tablici 114. u nastavku ove doktorske disertacije.

Tvrdnja podhipoteze H2.1 je potvrđena. Odluka se temelji na analizi *posttest* provjere znanja koja se, kao i u provedenom *predistraživanju*, u skraćenom obliku spominje u nastavku teksta u tablici 114.

Tablica 114. Skraćeni prikaz analize odgovora iz provedenog *posttesta* u prvom glavnom istraživanju

	Ukupni rezultat (uk. broj pitanja = 32)	
	Eksp.	Kont.
Grupa ispitanika		
Prosjek bodova	14,37	11,81
Stand. devijacija	5,88	5,07
Broj ispitanika	59	59
t vrijednost	2,53	
p vrijednost	0,012	

*Eksp. = *eksperimentalna* grupa, *Kont. = *kontrolna* grupa

Unutar tablice 114. navode se bodovi za sva pitanja *posttest* provjere znanja (ukupno 30 pitanja), koja su bila *eksperimentalnoj* i *kontrolnoj* grupi na raspolaganju te je nad njima provedena t-test analiza. Izračunata **t vrijednost iznosi 2.53**, dok je **p vrijednost 0.0127**, čime se zaključuje kako između ispitanika *eksperimentalne* (N=59) i *kontrolne* (N=59) grupe ispitanika **postoji statistički značajna razlika**. Prosječan broj bodova u *posttest* provjeri znanja u *eksperimentalnoj* grupi ispitanika, bio je za **21.67%** veći u odnosu na *kontrolnu* grupu ispitanika.

Obzirom na rezultat prosječnih bodova *posttest* provjere znanja u okviru **prvog glavnog istraživanja**, gdje su analizirani rezultati samo onih ispitanika koji su ostvarili **minimalno 50% od ukupnih** bodova, zaključuje se kako između ispitanika *eksperimentalne* (N=59) i *kontrolne* (N=59) grupe **postoji statistički značajna razlika** čime se potvrđuje podhipoteza H2.1 ove doktorske disertacije.

Treća i četvrta podhipoteza ove disertacije glase:

H2.2. Bez obzira na spol ispitanika, **50% najbolje** rangiranih studenata *eksperimentalne* grupe ispitanika, **prvog glavnog istraživanja**, ostvarit će statistički značajniji rezultat u odnosu na **50% najbolje** rangiranih studenata *kontrolne* grupe ispitanika.

H2.3. Bez obzira na spol ispitanika, **50% najlošije** rangiranih studenata *eksperimentalne* grupe ispitanika, **prvog glavnog istraživanja**, ostvarit će statistički značajniji rezultat u odnosu na **50% najlošije** rangiranih studenata *kontrolne* grupe ispitanika.

Kako bi se podhipoteze H2.2 i H2.3 potvrdile, u okviru **prvog glavnog istraživanja** provedena je *predtest* provjera znanja na temelju koje se dobio popis ispitanika koji su zadovoljili uvjet o ostvarivanju **minimalno 50% od ukupnog broja** bodova. Nakon provedene *posttest* provjere znanja, vidjelo se tko je od ranijih ispitanika odustao od sudjelovanja u istraživanju, te je bilo moguće provesti t-test analizu rezultata kako bi se potvrdile ili odbacile hipoteze H2.2 i H2.3. Ispitanici *kontrolne* i *eksperimentalne* skupine grupiraju se tako da se izdvaja **50% najboljih** i **50% najlošijih** iz obje grupe.

Slijedi prikaz rezultata gdje se uspoređuje 50% **najboljih** ispitanika iz *eksperimentalne* grupe (N=60) s 50% **najboljih** ispitanika iz *kontrolne* grupe (N=59), isto kao prikaz rezultata gdje se uspoređuje 50% **najlošijih** ispitanika iz *eksperimentalne* grupe (N=39) s 50% **najlošijih** ispitanika iz *kontrolne* grupe (N=43). Ukupan broj pitanja u *posttest* provjeri znanja bio je 30, dok je ukupan broj ispitanika, koji su sudjelovali u *posttest* provjeri znanja, bio **201**.

Tablica 115. Prikaz rezultata za **50% najboljih** i **50% najlošijih** ispitanika *eksperimentalne* i *kontrolne* grupe

Grupa ispitanika	Ukupni rezultat 50% najboljih ispitanika		Ukupni rezultat 50% najlošijih ispitanika	
	Eksperimentalna grupa	Kontrolna grupa	Eksperimentalna grupa	Kontrolna grupa
Prosjek bodova	14,40	11,81	12,03	10,65
Stand. devijacija	5,84	5,07	5,63	4,50
Broj ispitanika	60	59	39	43
t vrijednost	2,578		1,226	
p vrijednost	0,011		0,223	

Tablica 115. prikazuje odnos između *eksperimentalne* i *kontrolne* grupe ispitanika. Kao što je ranije navedeno, uspoređuje se **50% najboljih** ispitanika iz *eksperimentalne* grupe s **50% najboljih** ispitanika iz *kontrolne* grupe, isto kao i **50% najlošijih** ispitanika iz *eksperimentalne* grupe s **50% najlošijih** ispitanika iz *kontrolne* grupe.

- Iz tablice 115. vidljivo je kako između **50% najboljih** ispitanika **postoji statistički značajna razlika** kod bodova iz *posttest* provjere znanja. Izračunata **t vrijednost** iznosi **2,578**, dok **p vrijednost** iznosi **0,011**. *Eksperimentalna* skupina ispitanika (N=60) ostvarila je u *posttest* provjeri znanja bolji rezultat od *kontrolne* skupine ispitanika (N=59) za **21,93%**.

S obzirom na rezultat bodova *posttest* provjere znanja u okviru *prvog glavnog istraživanja*, gdje je napravljena analiza **50% najboljih** ispitanika iz *eksperimentalne* grupe (N=60) s **50% najboljih** ispitanika iz *kontrolne* grupe (N=59), zaključuje se kako između navedenih skupina **postoji statistički značajna razlika** koja se temelji na t-test analizi gdje je **p vrijednost 0,011**, čime se i **potvrđuje podhipoteza H2.2** ove doktorske disertacije.

- U analizi **50% najlošijih** ispitanika, izračunata **t vrijednost** iznosi **1,226**, dok **p vrijednost** iznosi **0,223**. Zaključak jest kako **statistički značajna razlika**, u slučaju analize 50% najlošijih ispitanika, **ne postoji**, unatoč većoj prosječnoj vrijednosti bodova koja je evidentirana u *eksperimentalnoj* grupi ispitanika. *Eksperimentalna* skupina ispitanika (N=39) ostvarila je u *posttest* provjeri znanja bolji rezultat od *kontrolne* skupine ispitanika (N=43) za **12,96%**.

U slučaju podhipoteze H2.3 gdje je napravljena analiza **50% najlošijih** ispitanika iz *eksperimentalne* grupe (N=39) i **50% najlošijih** ispitanika iz *kontrolne* grupe (N=43), zaključuje se kako između navedenih skupina **ne postoji statistički značajna razlika**, čime se **odbacuje podhipoteza H2.3** ove doktorske disertacije.

Peta i šesta podhipoteza ove disertacije glase:

H2.4. Bez obzira na predznanje ispitanika, studenti **muškog spola** *eksperimentalne* grupe u *prvom glavnom istraživanju* ostvarit će statistički značajniji rezultat u odnosu na studente **muškog spola** *kontrolne* grupe ispitanika.

H2.5. Bez obzira na predznanje ispitanika, studenti **ženskog spola** *eksperimentalne* grupe u *prvom glavnom istraživanju* ostvarit će statistički značajniji rezultat u odnosu na studente **ženskog spola** *kontrolne* grupe ispitanika

Kako bi se podhipoteze H2.4 i H2.5 potvrdile, u okviru *prvog glavnog istraživanja* provedena je *posttest* provjera znanja na temelju koje se dobio popis ispitanika koji su zadovoljili uvjet za sudjelovanje u istraživanju, te je bilo moguće provesti t-test analizu rezultata kako bi se potvrdile ili odbacile hipoteze H2.4 i H2.5. Ispitanici *kontrolne* i *eksperimentalne* skupine grupiraju se **prema spolu**, te se provodi analiza između **muškog spola** *kontrolne* i *eksperimentalne* grupe, isto kao i analiza ispitanika **ženskog spola** *kontrolne* i *eksperimentalne* grupe. Slijedi prikaz rezultata gdje se uspoređuju muški ispitanici iz *eksperimentalne* grupe (N=80) s muškim ispitanicima iz *kontrolne* grupe (N=77), isto kao prikaz rezultata gdje se uspoređuju **ženski** ispitanici iz *eksperimentalne* grupe (N=19) sa **ženskim** ispitanicima iz *kontrolne* grupe (N=25). Ukupan broj pitanja u *posttest* provjeri znanja bio je 30, dok je ukupan broj ispitanika koji su sudjelovali u *posttest* provjeri znanja bio **201**.

Tablica 116. Prikaz rezultata usporedbe **muških** i usporedbe **ženskih** ispitanika *eksperimentalne* i *kontrolne* grupe

Grupa ispitanika	Ukupni rezultat ispitanici muškog spola		Ukupni rezultat ispitanici ženskog spola	
	Eksperimentalna grupa	Kontrolna grupa	Eksperimentalna grupa	Kontrolna grupa
Prosjeck bodova	13,35	11,23	13,95	11,60
Stand. devijacija	5,69	5,04	6,59	4,31
Broj ispitanika	80	77	19	25
t vrijednost	2,462		1,427	
p vrijednost	0,0149		0,1610	

Tablica 116. prikazuje odnos između posebno muških i posebno ženskih ispitanika *eksperimentalne* i *kontrolne* grupe. Muški ispitanici iz *eksperimentalne* grupe (N=80) uspoređivani su sa muškim ispitanicima iz *kontrolne* grupe (N=77). U tablici 116. vidi se i usporedba **ženskih** ispitanika iz *eksperimentalne* grupe (N=19) sa **ženskim** ispitanicima iz *kontrolne* grupe (N=25).

- Iz tablice 116. vidljivo je kako između ispitanika **muškog spola** postoji **statistički značajna razlika** u slučaju bodova iz *posttest* provjere znanja. Izračunata **t vrijednost** iznosi **2,462**, dok **p vrijednost** iznosi **0,0149**. *Eksperimentalna* skupina ispitanika (N=80) ostvarila je u *posttest* provjeri znanja bolji rezultat od *kontrolne* skupine ispitanika (N=77) za **18,88%**.

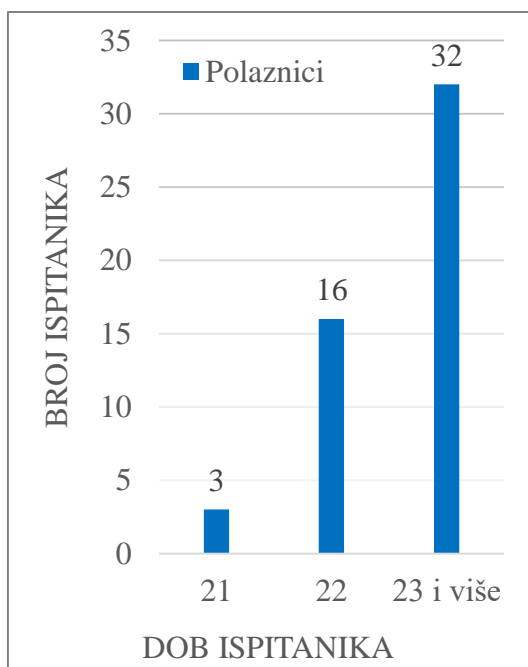
S obzirom na rezultat bodova *posttest* provjere znanja u okviru *prvog glavnog istraživanja*, gdje je napravljena usporedba između ispitanika **muškog spola** iz *eksperimentalne* grupe (N=80) s ispitanicima **muškog spola** iz *kontrolne* grupe (N=77), zaključuje se kako između navedenih skupina **postoji statistički značajna razlika** koja se temelji na t-test analizi gdje je **p vrijednost 0,0149**, čime se **podhipoteza H2.4** ove doktorske disertacije **potvrđuje**.

- U analizi između ispitanika **ženskog spola**, izračunata **t vrijednost** iznosi **1,427**, dok **p vrijednost** iznosi **0,161**. Zaključak jest kako **statistički značajna razlika**, u slučaju analize ispitanika **ženskog spola**, između *eksperimentalne* i *kontrolne* grupe, **ne postoji** unatoč većoj prosječnoj vrijednosti bodova koja je evidentirana u *eksperimentalnoj* grupi ispitanika. *Eksperimentalna* skupina ispitanika (N=19) ostvarila je u *posttest* provjeri znanja bolji rezultat od *kontrolne* skupine ispitanika (N=25) za **20,26%**.

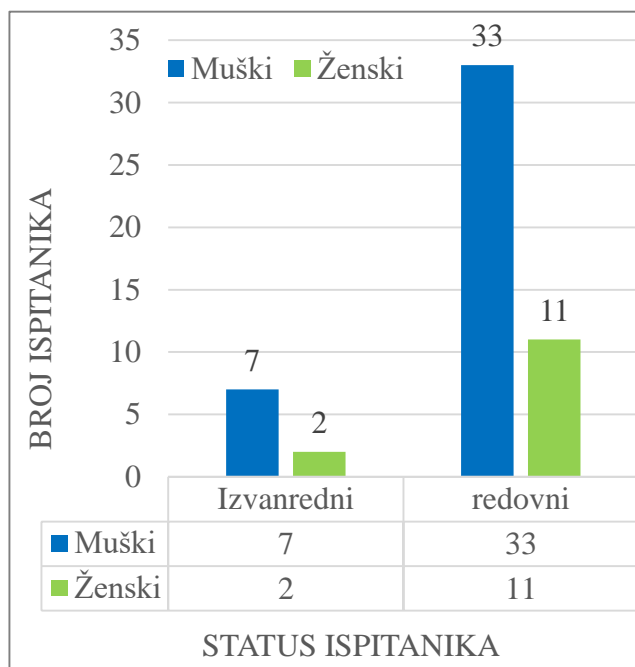
U slučaju podhipoteze H2.5 gdje se uspoređuju **ženski** ispitanici iz *eksperimentalne* grupe (N=19) sa **ženskim** ispitanicima iz *kontrolne* grupe (N=25), zaključuje se kako statistički značajna razlika između navedenih grupa ne postoji, bez obzira na sveukupni bolji rezultat kod *eksperimentalne* skupine ispitanika za **20,26%** u odnosu na *kontrolnu* skupinu ispitanika, čime se **podhipoteza H2.5** ove doktorske disertacije i **odbacuje**. Uzrok ovakvom rezultatu može biti u malom broju ispitanika.

6.3. DRUGO GLAVNO ISTRAŽIVANJE: E-TEČAJ "MULTIMEDIJA"

Ispitanici u *drugom glavnom istraživanju* bili su studenti **Fakulteta organizacije i informatike** u Varaždinu koji su pohađali kolegij "**Računalom posredovana komunikacija**" (skraćenog naziva **RPK**), na diplomskom studiju Informatike, u zimskom semestru akademske godine 2015./2016. **Ukupan broj** ispitanika, koji su dobrovoljno sudjelovali u istraživanju, bio je **53**. Ispitanici su bili podijeljeni u **dvije grupe po 25 studenata** u grupi. Od navedenog ukupnog broja ispitanika, 13 njih ili 24,53% je bilo ženskog, a 40 ili 75,47% muškog spola. Prosječna dob ispitanika bila je **23 i više godina**. *Pred i posttest* je u potpunosti ispunilo 46 ispitanika. *Anketni upitnik* u cijelosti je ispunio **51** student. Detaljniji uvid u dobnu strukturu prikazan je na slikama 53. i 54.



Slika 53. Dob ispitanika kolegija "Računalom posredovana komunikacija" (N=51)



Slika 54. Status ispitanika kolegija "Računalom posredovana komunikacija" (N=53)

6.3.1. Predtest analiza rezultata u provedenom drugom glavnom istraživanju

Polaznici kolegija "Računalom posredovana komunikacija", e-tečaja "Multimedija", primili su upute kako pristupiti ispunjavanju *predtest* provjeri znanja kojom se provjeravalo predznanje studenata. Studenti su temeljem evidencije na vježbama podijeljeni u **dvije grupe** (*eksperimentalna* grupa **G1** i *kontrolna* grupa **G2**). Prilikom provođenja *predtest* provjere znanja utvrđene su nepravilnosti, kao i kod provođenja *posttest* provjere znanja, te je ukupan broj ispitanika reduciran na 46. Broj ispitanika koji je sudjelovao u *anketnom upitniku* ostaje nepromijenjen te iznosi 51. Slijedi provjerava jednakosti između grupa.

Tablica 117. Usporedni prikaz *eksperimentalne* i *kontrolne* grupe nakon *predtesta* za provjeru znanja

Grupa 1 - Eksperimentalna grupa (G1)			Grupa 2 - Kontrolna grupa (G2)		
N = 23			N = 23		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
4	17	53,13	1	18	56,25
11	22	68,75	2	20	62,50
12	25	78,13	3	18	56,25
18	20	62,50	5	18	56,25
19	24	75,00	7	17	53,13
20	26	81,25	9	14	43,75
21	23	71,88	10	19	59,38
23	24	75,00	13	20	62,50
28	18	56,25	15	24	75,00
29	17	53,13	17	18	56,25
30	18	56,25	22	24	75,00
33	25	78,13	24	27	84,38
34	23	71,88	25	25	78,13
35	24	75,00	26	26	81,25
36	24	75,00	27	24	75,00
37	24	75,00	31	21	65,63
38	22	68,75	32	22	68,75
43	24	75,00	39	15	46,88
44	22	68,75	40	25	78,13
47	19	59,38	41	20	62,50
48	20	62,50	42	17	53,13
50	22	68,75	46	24	75,00
52	21	65,63	51	25	78,13

Prosječni bodovi grupe: 21,913 **Prosječni bodovi grupe: 20,913**

Tablica 118. Rezultati *predtesta* za *eksperimentalnu* (**G1**) grupu ispitanika (N=23)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	21,91	2,69	24	17-26

Tablica 118. prikazuje rezultate *predtesta* za provjeru znanja kod *eksperimentalne* (**G1**) grupe ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 21,91, uz standardnu devijaciju od 2,69. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 24. Raspon bodova kreće se od minimalno 17 do maksimalno 26. Ukupan broj mogućih bodova iznosi 32.

Tablica 119. Rezultati *predtesta* za *kontrolnu* (**G2**) grupu ispitanika (N=23)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	20,91	3,72	18	14-27

Rezultati *predtesta* za provjeru znanja kod *kontrolne* (**G2**) grupe ispitanika, prikazani su u tablici 119. Od ukupnog broja bodova, kontrolna grupa ostvarila je prosječnu vrijednost bodova u iznosu od 20,91, uz standardnu devijaciju od 3,72. Najčešći iznos (Mod) sakupljenih bodova iznosi 18. Raspon bodova koji su ispitanici ostvarili iznosi od 14 do 27.

Tablica 120. Testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta* svih ispitanika *eksperimentalne* (**G_E**) grupe (N=23) i *kontrolne* (**G_K**) grupe, (N=23)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G_E	23	21,91	2,70	1,04	0,3029
G_K	23	20,91	3,73		

G_E = *eksperimentalna* grupa; **G_K** = *kontrolna* grupa

Tablica 120. prikazuje izračun statističke značajnosti na temelju rezultata *predtesta* za provjeru znanja. Izračun se temelji na usporedbi ispitanika *eksperimentalne* (**G_E**) grupe te ispitanika *kontrolne* (**G_K**) grupe. Intermedijalna **vrijednost t** iznosi **1,04**. Izračunata **p vrijednost** iznosi **0,30** čime se može zaključiti kako između ispitanika *eksperimentalne* (**G_E**) grupe te ispitanika *kontrolne* (**G_K**) grupe **ne postoji statistički značajna razlika** obzirom na prosječne rezultate *predtesta*.

6.3.2. Posttest analiza rezultata u provedenom drugom glavnom istraživanju

Polaznici kolegija "Računalom posredovana komunikacija" primili su upute kako pristupiti ispunjavanju *posttest* provjeri znanja, kojom se provjeravalo znanje studenata iz sadržaja obuhvaćenih e-tečajem "Multimedija". *Eksperimentalne* i *kontrolne* grupe nisu bile mijenjane s obzirom na raniju postignutu jednakost između grupa.

Tablica 121. Usporedni prikaz *eksperimentalne* i *kontrolne* grupe nakon *posttesta* za provjeru znanja

Grupa 1 - Eksperimentalna grupa (G1)			Grupa 2 - Kontrolna grupa (G2)		
N = 23			N = 23		
Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %	Oznaka ispitanika	Bodovi ispitanika	Riješenost provjere u %
4	27	84,375	1	13	40,625
11	27	84,375	2	17	53,125
12	26	81,25	3	14	43,75
18	23	71,875	5	12	37,5
19	15	46,875	7	9	28,125
20	25	78,125	9	21	65,625
21	22	68,75	10	12	37,5
23	19	59,375	13	15	46,875
28	21	65,625	15	15	46,875
29	23	71,875	17	16	50
30	27	84,375	22	19	59,375
33	28	87,5	24	20	62,5
34	23	71,875	25	20	62,5
35	13	40,625	26	20	62,5
36	22	68,75	27	23	71,875
37	22	68,75	31	16	50
38	21	65,625	32	16	50
43	24	75	39	14	43,75
44	28	87,5	40	17	53,125
47	19	59,375	41	13	40,625
48	25	78,125	42	19	59,375
50	16	50	46	20	62,5
52	13	40,625	51	21	65,625

Prosječni bodovi grupe: 22,130

Prosječni bodovi grupe: 16,609

Tablica 122. Rezultati *posttesta* za *eksperimentalnu* (**G1**) grupu ispitanika (N=23)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
31	22,13	4,54	27	13-28

Tablica 122. prikazuje rezultate *predtesta* za provjeru znanja kod *eksperimentalne* (**G1**) grupe ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 22,13, uz standardnu devijaciju od 4,54. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 27. Raspon bodova kreće se od minimalno 13 do maksimalno 28. Ukupan broj mogućih bodova iznosi 31.

Tablica 123. Rezultati *posttesta* za *kontrolnu* (**G2**) grupu ispitanika (N=23)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
31	16,61	3,59	20	9-23

Rezultati *predtesta* za provjeru znanja kod *kontrolne* (**G2**) grupe ispitanika, prikazani su u tablici 123. Od ukupnog broja bodova, kontrolna grupa ostvarila je prosječnu vrijednost bodova u iznosu od 16,61, uz standardnu devijaciju od 3,59. Najčešći iznos (Mod) sakupljenih bodova iznosi 20. Raspon bodova koji su ispitanici ostvarili iznosi od 9 do 23.

Tablica 124. Testiranje *statističke značajnosti razlike* metodom t-testa između rezultata *posttesta svih ispitanika eksperimentalne* (**G_E**) grupe, (N=23) i *kontrolne* (**G_K**) grupe, (N=23)

Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
G_E	23	22,13	4,55	4,57	0,0001
G_K	23	16,61	3,59		

G_E = *eksperimentalna* grupa; **G_K** = *kontrolna* grupa

t = odnos između prosječnih vrijednosti *eksperimentalne* i *kontrolne* grupe, te standardne pogreške razlike.

p = signifikantnost, tj. što je p vrijednost manja to je manja i empirijski utvrđena vjerojatnost odbacivanja istinite hipoteze i obratno.

Tablica 124. prikazuje izračun *statističke značajnosti* na temelju rezultata *posttesta* za provjeru znanja. Izračun se temelji na usporedbi ispitanika *eksperimentalne* (**G_E**) grupe te ispitanika *kontrolne* (**G_K**) grupe. Intermedijalna **vrijednost t** iznosi **4,57**. Izračunata **p vrijednost** iznosi **0,0001** čime se može zaključiti, uz mogućnost pogreške od 1%, kako između ispitanika *eksperimentalne* (**G_E**) grupe te ispitanika *kontrolne* (**G_K**) grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*.

Prosječan broj bodova prije eksperimenta za *eksperimentalnu grupu* iznosio je **21,91**, dok je za *kontrolnu grupu* iznosio **20,91**. *Eksperimentalna* grupa postigla je bolji rezultat za **4,78%**. Pomoću *predtest provjere znanja* i dobivenih pokazatelja, izračunate su **p vrijednosti** na temelju kojih se vidi kako **između grupa ne postoji statistički značajna razlika**. *Eksperimentalna* grupa pristupila je eksperimentu nakon kojeg slijedi *posttest provjera znanja*.

Prosječan broj bodova nakon eksperimenta za *eksperimentalnu grupu* se povećao se za **1%** te je iznosio **22,13 bodova**, dok se za *kontrolnu grupu* smanjio za **25,88%** te je iznosio **16,61 bodova**. *Eksperimentalna* grupa postigla je bolji rezultat za **33,23%**. Pomoću *posttest provjere znanja* izračunate su **p vrijednosti** na temelju kojih se vidi kako **između grupa postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*.

U tablici 125. ove disertacije prikazuje se dodatna analiza **otvorenog tipa** pitanja *posttest* provjere znanja u provedenom *drugom glavnom istraživanju*. Izračunat je prosjek, standardna devijacija, isto kao i statistička značajnost rezultata. U analizu je uključena varijanta gdje se pitanjima otvorenog tipa (tj. pitanjima esejskog tipa) dodaje veći broj bodova.

Tablica 125. Analiza otvorenog tipa pitanja *posttest* provjere znanja u *drugom glavnom istraživanju*

	Otvoreni tip pitanja (n=6)		Otvoreni tip pitanja (n=6)*	
	Eksp.	Kont.	Eksp.	Kont.
Grupa ispitanika				
Prosjek bodova	4,30	3,35	8,61	6,70
Stand. devijacija	1,36	1,56	2,73	3,11
t vrijednost	2,22		2,22	
p vrijednost	0,031		0,031	

n = broj pitanja u provjeri znanja

* = analiza u slučaju **izmjene sustava bodova** kod pitanja otvorenog tipa

Tablica 125. pokazuje analizu otvorenog tipa pitanja iz *posttest* provjere znanja koja predstavlja dopunu ranije prezentiranih analiza iz **poglavlja 6.3.2**. Vidljivo je kako *eksperimentalna* skupina ispitanika (**Eksp**), koja broji ukupno 23 ispitanika, ima **veći prosječan broj bodova** kao i standardnu devijaciju bodova u odnosu na *kontrolnu* skupinu ispitanika (**Kont**), koja broji ukupno 23 ispitanika. **Statistički značajna razlika**, između navedenih skupina, u *drugom glavnom istraživanju* je postignuta.

Isto kao kod *predistraživanja* i *prvog glavnog istraživanja*, svako pitanje ili zadatak u *posttestu* nosi **jedan bod**. U slučaju kada se otvoreni tip pitanja (tj. pitanja esejskog tipa) bodovao s **dva boda**, **statistička značajnost rezultata** ne bi bila promijenjena, isto kao niti bilo koji drugi pokazatelj koji bi utjecao na promjenu iznesenih zaključaka. **Standardna devijacija** i **prosječna vrijednost** bodova proporcionalno se udvostručuju čime se ne mijenja daljnji tijek analize. Zbog jednostavnosti prikaza i ranijih izračuna, odlučeno je zadržati postojeći sustav bodovanja gdje svako pitanje nosi jedan bod, bez obzira radi li se o pitanjima otvorenog ili zatvorenog tipa.

U nastavku analize, dodaje se još jedan kriterij koji se odnosi na selekciju studenata koji su ostvarili **minimalno 50% ukupnih bodova** u *predtest* provjeri znanja. U provedenom *predtestu drugog glavnog istraživanja* u okviru ovog doktorskog istraživanja, sudjelovalo je 53 ispitanika. *Predtest* je brojao 32 pitanja, od kojih su 26 pitanja zatvorenog tipa i 6 pitanja otvorenog tipa. Svako pitanje nosilo je jedan bod i služilo je utvrđivanju studentovog predznanja.

Uz navedenu analizu koja je detaljno prikazana u ovom poglavlju, napravljena je dodatna analiza bodova samo nad ispitanicima koji su zadovoljili dodatni uvjet, koji je vezan za ostvarivanje **minimalno 50% ukupnih bodova** u provedenom *predtestu drugog glavnog istraživanja*. Od ukupnog broja ispitanika, njih 51 je zadovoljilo navedeni uvjet. Iz ranije definiranih grupa uklonjena su dva studenta koji nisu imali ostvareno minimalno 50% ukupnih bodova, nakon čega su rezultati ponovno analizirani.

Provedena je analiza *posttest* provjere znanja nad pitanjima **zatvorenog tipa** (ukupno 25 pitanja), nad pitanjima **otvorenog tipa** (ukupno 6 pitanja), te nad **ukupno** ostvarenim bodovima (ukupno 31 pitanja). Rezultati su uspoređivani na razini uparenih grupa koje su i ranije korištene u ovoj doktorskoj disertaciji, isto kao i na skupnoj razini *eksperimentalne* (N=23) i *kontrolne* grupe ispitanika (N=21). U tablici 126. vidljiv je usporedni prikaz navedenih elemenata i podjela *posttest rezultata iz drugog glavnog istraživanja*.

Tablica 126. Usporedni prikaz analize odgovora iz provedene *posttest* provjere znanja u drugom glavnom istraživanju

	Zatvoreni tip pitanja (uk. broj pitanja = 25)		Otvoreni tip pitanja (uk. broj pitanja = 6)		Ukupni rezultat (uk. broj pitanja = 31)	
	Eksp.	Kont.	Eksp.	Kont.	Eksp.	Kont.
Grupa ispitanika						
Prosjeck bodova	15,61	13,19	6,78	5,62	22,39	18,81
Stand. devijacija	4,35	3,34	3,03	2,69	6,06	4,06
Broj ispitanika	23	21	23	21	23	21
t vrijednost	2,05		1,34		2,28	
p vrijednost	0,046		0,187		0,027	

*Eksp. = *eksperimentalna* grupa, *Kont. = *kontrolna* grupa

Vidljivo je kako su **prosječni bodovi** i standardna devijacija u sva tri slučaja **veći kod eksperimentalne grupe** ispitanika. Izračunata **p vrijednost** pokazuje kako u drugom slučaju s pitanjima otvorenog tipa **ne postoji statistički značajna razlika**. U druga dva slučaja, s pitanjima zatvorenog tipa i kod ukupne analize bodova, izračunata **p vrijednost** pokazuje kako je *eksperimentalna* grupa postigla rezultat koji osigurava **statistički značajnu razliku**.

Dodatna analiza *posttest* rezultata za **sva pitanja** iz drugog glavnog istraživanja pokazuje odnos postignutih bodova između ranije uparenih grupa, isto kao i između studenata koji su u *predtestu drugog glavnog istraživanja* postigli **50% (ili više)** od ukupnih bodova. Unutar navedene analize vidljivi su bodovi za pitanja zatvorenog tipa (n=25) i otvorenog tipa (n=6) koje su studenti ostvarili kroz *posttest* provjeru znanja. **Sve eksperimentalne** grupe imaju **veći prosječan broj** bodova od *kontrolnih* grupa. Izračunata **t vrijednost iznosi 2,28** dok je **p vrijednost 0.027**, čime se zaključuje kako između ispitanika *eksperimentalne* (N=23) i *kontrolne* (N=21) grupe **postoji statistički značajna razlika**.

U nastavku disertacije navodi se statistička analiza odgovora koji su prikupljeni iz *pretest* i *posttest* provjera znanja u *drugom glavnom istraživanju*. Izračunata je jedinična težina pitanja, prosječna težina pitanja i standardna devijacija.

Tablica 127. Analiza težine pitanja u provedenom *pretestu drugog glavnog istraživanja*

Pitanje zatvorenog tipa	Broj točnih odgovora (maks. 53 odgovora)	Težina pitanja
1	16	0,30
2	51	0,96
3	37	0,70
4	33	0,62
5	32	0,60
6	35	0,66
7	36	0,68
8	34	0,64
9	51	0,96
10	6	0,11
11	25	0,47
12	32	0,60
13	30	0,57
14	39	0,74
15	46	0,87
16	45	0,85
17	47	0,89
18	33	0,62
19	26	0,49
20	52	0,98
21	29	0,55
22	37	0,70
23	30	0,57
24	50	0,94
25	33	0,62
26	52	0,98
Prosječna težina pitanja:		0,68
Standardna devijacija:		0,21
Pitanje otvorenog tipa	Broj točnih odgovora (maks. 53 odgovora)	Težina pitanja
1	27	0,51
2	32	0,60
3	42	0,79
4	24	0,45
5	37	0,70
6	30	0,57
Prosječna težina pitanja:		0,60
Standardna devijacija:		0,12

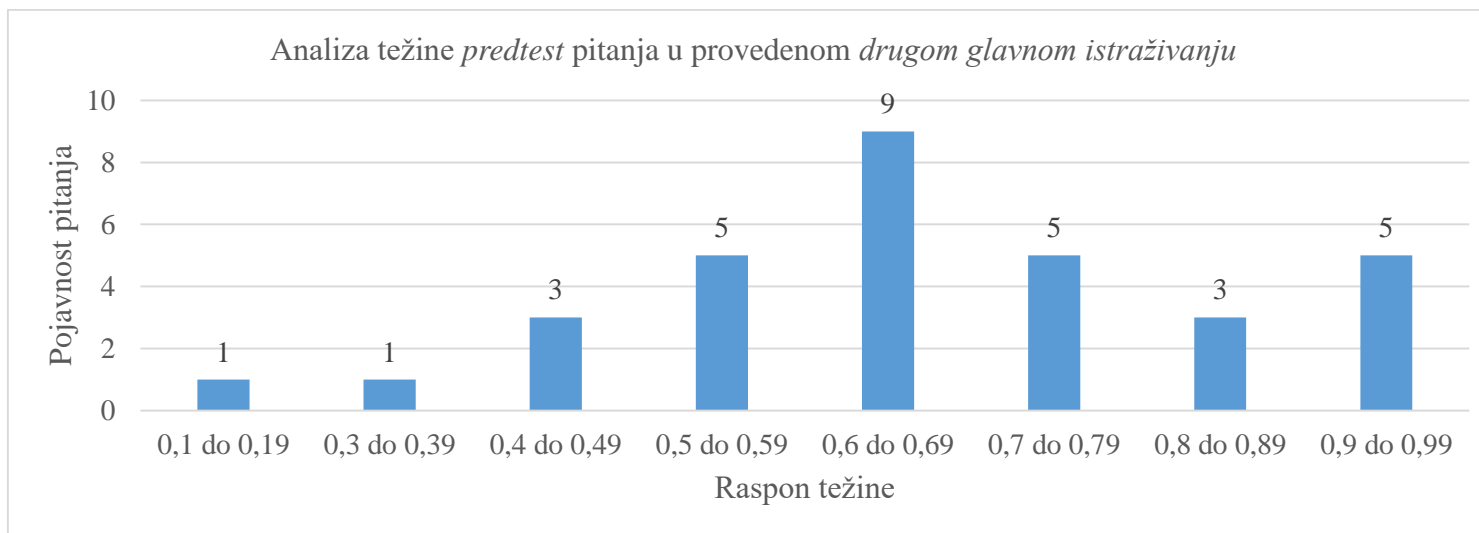
Prosječna težina pitanja **zatvorenog tipa** bila je **0,68**, dok je prosječna težina pitanja kod **otvorenog tipa** bila **0,60**. Što je vrijednost pitanja bliža 1, to je studentima pitanje bilo lakše.

U nastavku rada prikazuje se analiza odgovora koji su prikupljeni iz *posttest* provjere znanja koja je provedena u okviru *drugog glavnog istraživanja*.

Tablica 128. Analiza težine pitanja u provedenom *posttestu drugog glavnog istraživanja*

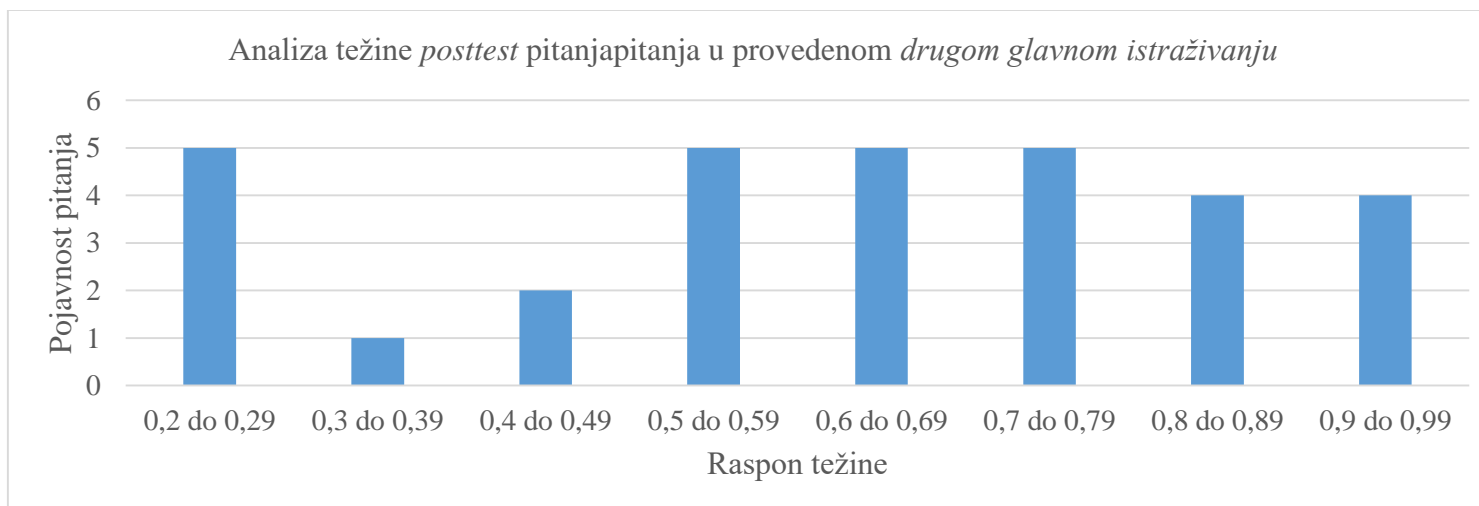
Pitanje zatvorenog tipa	Broj točnih odgovora (maks. 46 odgovora)	Težina pitanja
1	35	0,76
2	31	0,67
3	36	0,78
4	43	0,93
5	38	0,83
6	42	0,91
7	28	0,61
8	12	0,26
9	29	0,63
10	20	0,43
11	23	0,50
12	25	0,54
13	13	0,28
14	42	0,91
15	31	0,67
16	22	0,48
17	29	0,63
18	32	0,70
19	23	0,50
20	40	0,87
21	45	0,98
22	13	0,28
23	33	0,72
24	12	0,26
25	18	0,39
Prosječna težina pitanja:		0,62
Standardna devijacija:		0,22
Pitanje otvorenog tipa	Broj točnih odgovora (maks. 46 odgovora)	Težina pitanja
1	34	0,74
2	23	0,50
3	27	0,59
4	13	0,28
5	38	0,83
6	41	0,89
Prosječna težina pitanja:		0,64
Standardna devijacija:		0,23

Prosječna težina pitanja **zatvorenog tipa** bila je **0,62**, dok je prosječna težina pitanja kod **otvorenog tipa** bila **0,64**. Težina pitanja bila je gotovo identična između *predtest* i *posttest* provjere znanja. Bitno je napomenuti da što je vrijednost pitanja bliža 1, to je pitanje lakše.



Raspon težine	Pojavnost pitanja
0,1 do 0,19	1
0,3 do 0,39	1
0,4 do 0,49	3
0,5 do 0,59	5
0,6 do 0,69	9
0,7 do 0,79	5
0,8 do 0,89	3
0,9 do 0,99	5

Slika 55. Analiza težine pitanja iz *pretesta* koji je korišten u *drugom glavnom istraživanju*



Raspon težine	Pojavnost pitanja
0,2 do 0,29	5
0,3 do 0,39	1
0,4 do 0,49	2
0,5 do 0,59	5
0,6 do 0,69	5
0,7 do 0,79	5
0,8 do 0,89	4
0,9 do 0,99	4

Slika 56. Analiza težine pitanja iz *posttesta* koji je korišten u *drugom glavnom istraživanju*

6.3.3. Analiza rezultata anketnog upitnika u provedenom drugom glavnom istraživanju

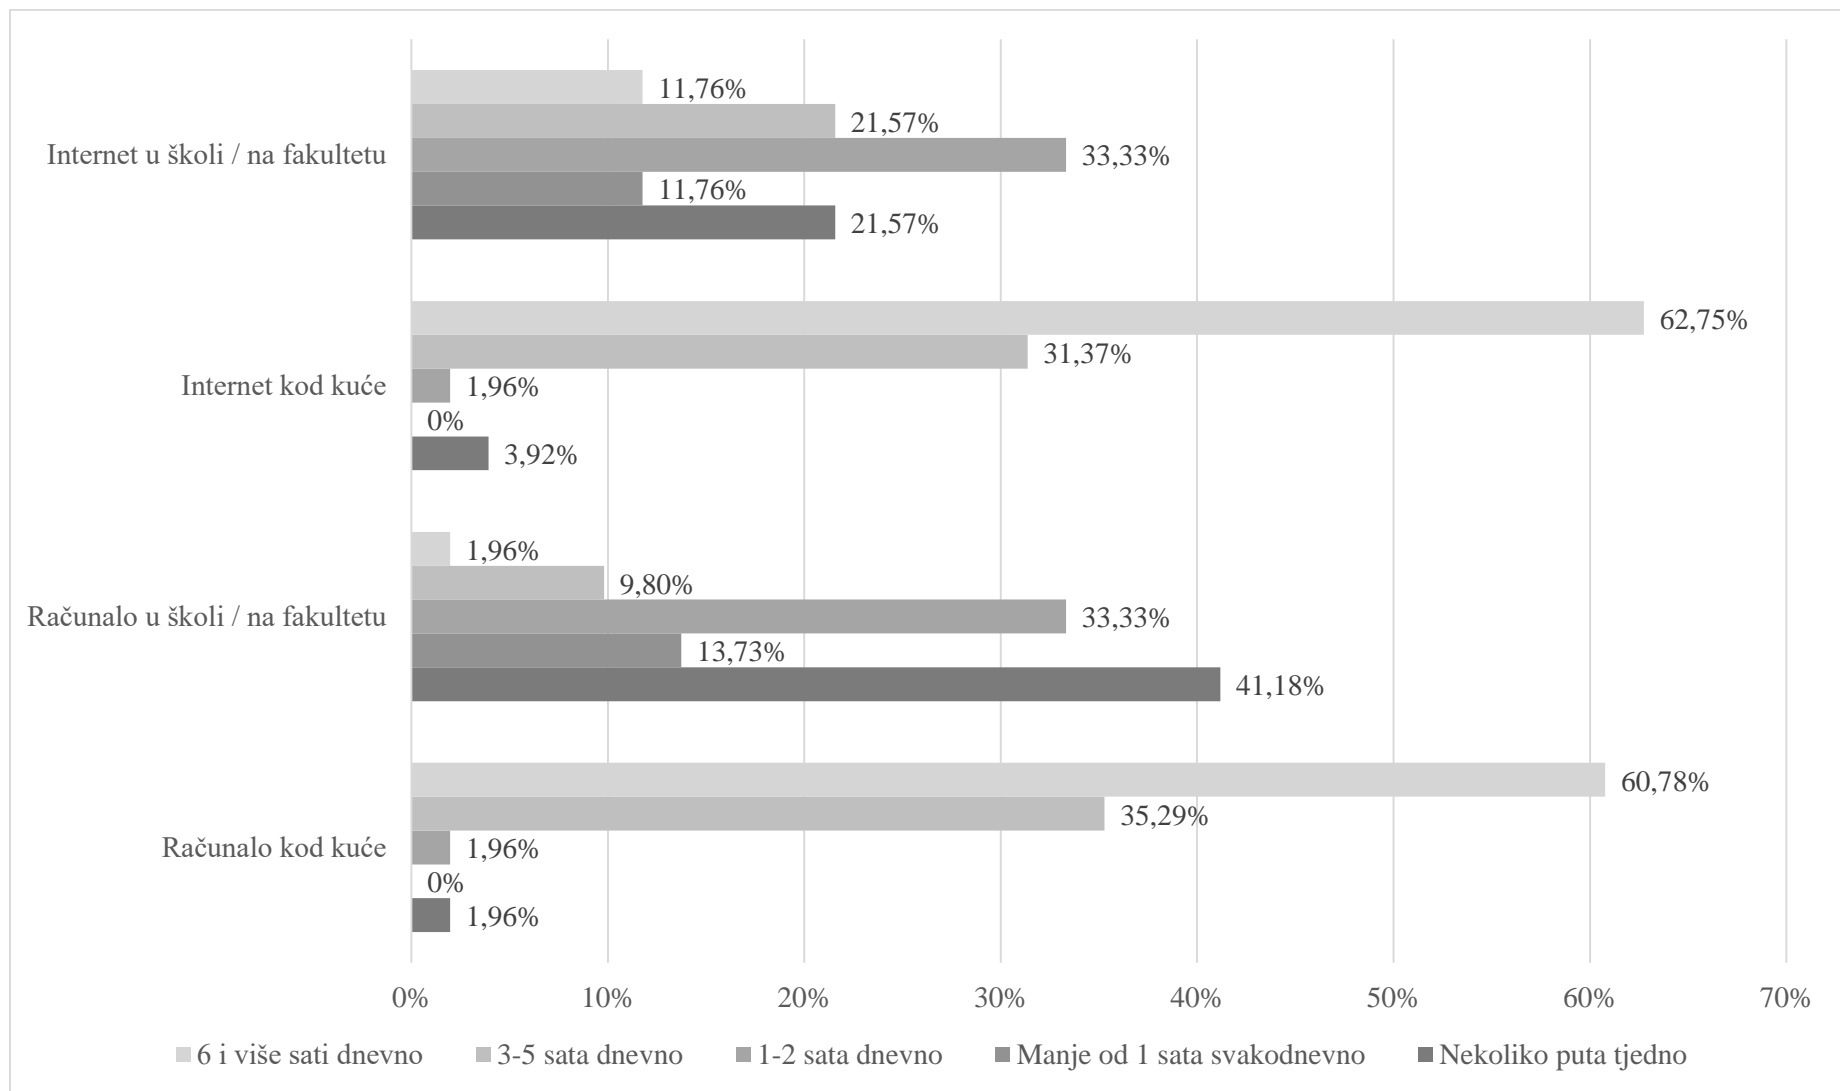
U provedenom *drugom glavnom istraživanju* anketni upitnik valjano je ispunio **51 ispitanik** od ukupno 53 polaznika e-tečaja. Rezultat dobne raspodjele ispitanika prikazan je u tablici 129. U nastavku se navode deskriptivni pokazatelji za **prvu cjelinu anketnog upitnika** pod nazivom "*Osobni podaci*". **Prva cjelina anketnog upitnika** sastoji se od **tri skale** koje se navode u nastavku rada. Cronbach alpha koeficijent za prve tri skale iznosi ,677 uz broj čestica od 12.

Tablica 129. Analiza odgovora svih ispitanika u provedenom *drugom glavnom istraživanju* prema učestalosti korištenja računala i Internet tehnologije (N=51)

	Računalo kod kuće		Računalo u školi / na fakultetu		Internet kod kuće		Internet u školi / na fakultetu	
	Frekv.	%	Frekv.	%	Frekv.	%	Frekv.	%
Nekoliko puta tjedno	1	2%	21	42%	2	4%	11	22%
Manje od 1 sata svakodnevno	0	0%	7	13%	0	0%	6	11%
1-2 sata dnevno	1	2%	17	33%	1	2%	17	34%
3-5 sata dnevno	18	35%	5	10%	16	32%	11	22%
6 i više sati dnevno	31	61%	1	2%	32	62%	6	11%
Ukupno	51	100 %	51	100 %	51	100 %	51	100%

Frekv. = frekvencija odgovora

Iz tablice 129. može se zaključiti kako ispitanici **kod kuće** koriste računalo i Internet **šest i više sati** dnevno. Ispitanici **na fakultetu** računalo koriste **nekoliko puta tjedno**, a Internet koriste **jedan do dva sata** dnevno. U nastavku rada prikazana je analiza odgovora svih ispitanika u provedenom *drugom glavnom istraživanju* prema učestalosti korištenja računala i Internet tehnologije.



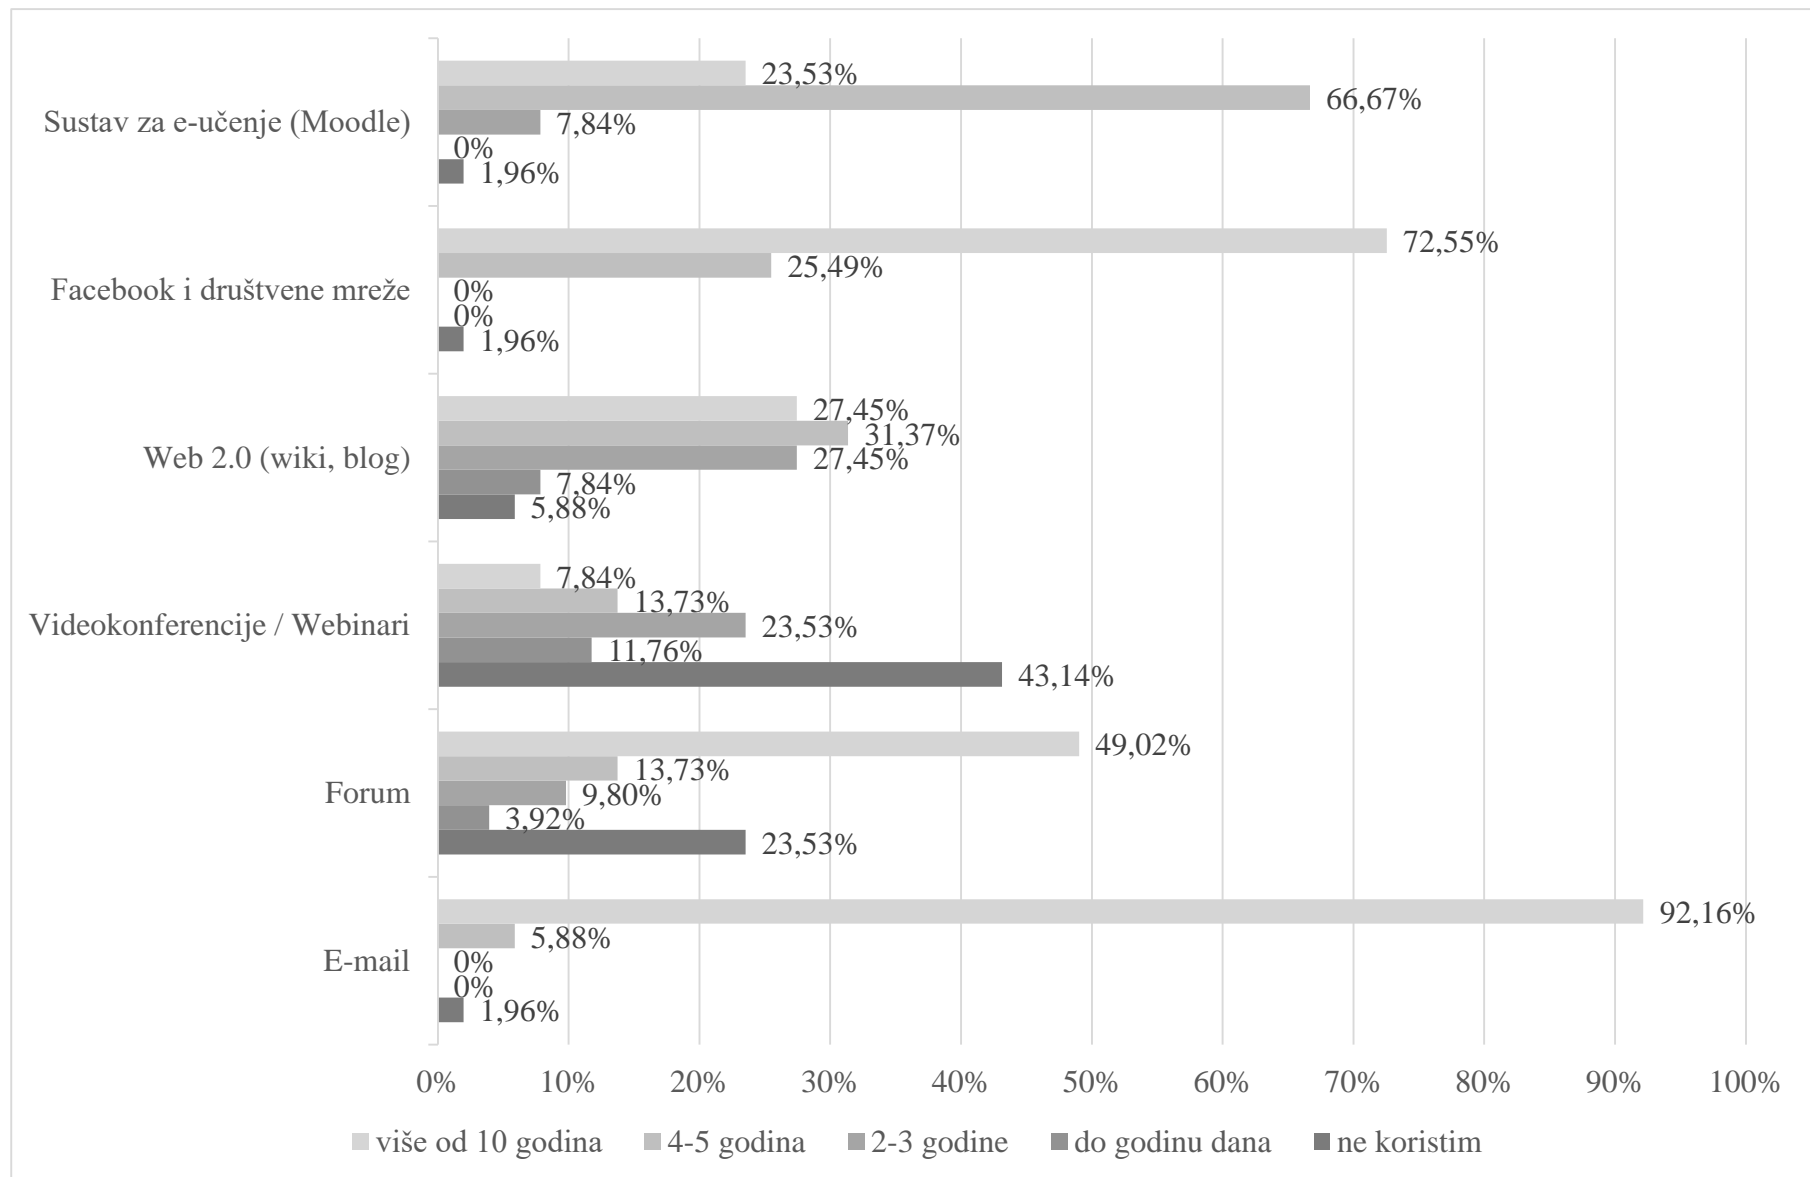
Slika 57. Grafički prikaz analize odgovora svih ispitanika u provedenom *drugom glavnom istraživanju* prema učestalosti korištenja računala i Internet tehnologije (N=51; uključuje *eksperimentalnu* i *kontrolnu* skupinu ispitanika)

Tablica 130. Analiza odgovora svih ispitanika u provedenom *drugom glavnom istraživanju* s obzirom na **dužinu korištenja** (u godinama) **Internet tehnologije** (N=51)

	E-mail		Forum		Videokonferencije / Webinar		Web 2.0 (wiki, blog)		Facebook i društvene mreže		Sustav za e-učenje (Moodle)	
	f	%	f	%	f	%	f	%	f	%	f	%
Ne koristim	1	2%	12	24%	22	44%	3	6%	1	2%	1	2%
Do godinu dana	0	0%	2	4%	6	12%	4	7%	0	0%	0	0%
2-3 godine	0	0%	5	11%	12	23%	14	28%	0	0%	4	8%
4-5 godina	3	6%	7	12%	7	13%	16	32%	13	25%	34	67%
Više od 10 godina	47	92%	25	49%	4	8%	14	27%	37	72%	12	23%
Ukupno	51	100%	51	100%	51	100%	51	100%	51	100%	51	100%

f = frekvencija odgovora

Iz tablice 130. može se zaključiti kako ispitanici u provedenom *drugom glavnom istraživanju* koriste **e-mail**, **forum** i **društvene mreže** više od 10 godina. **Videokonferencije** i **webinare** ne koriste uopće, dok **web 2.0 alate** koriste četiri do pet godina. Ispitanici koriste **sustave za e-učenje**, poput Moodle-a, četiri do pet godina. U nastavku rada prikazana je analiza odgovora svih ispitanika u provedenom *drugom glavnom istraživanju* prema **učestalosti korištenja računala i Internet tehnologije**.

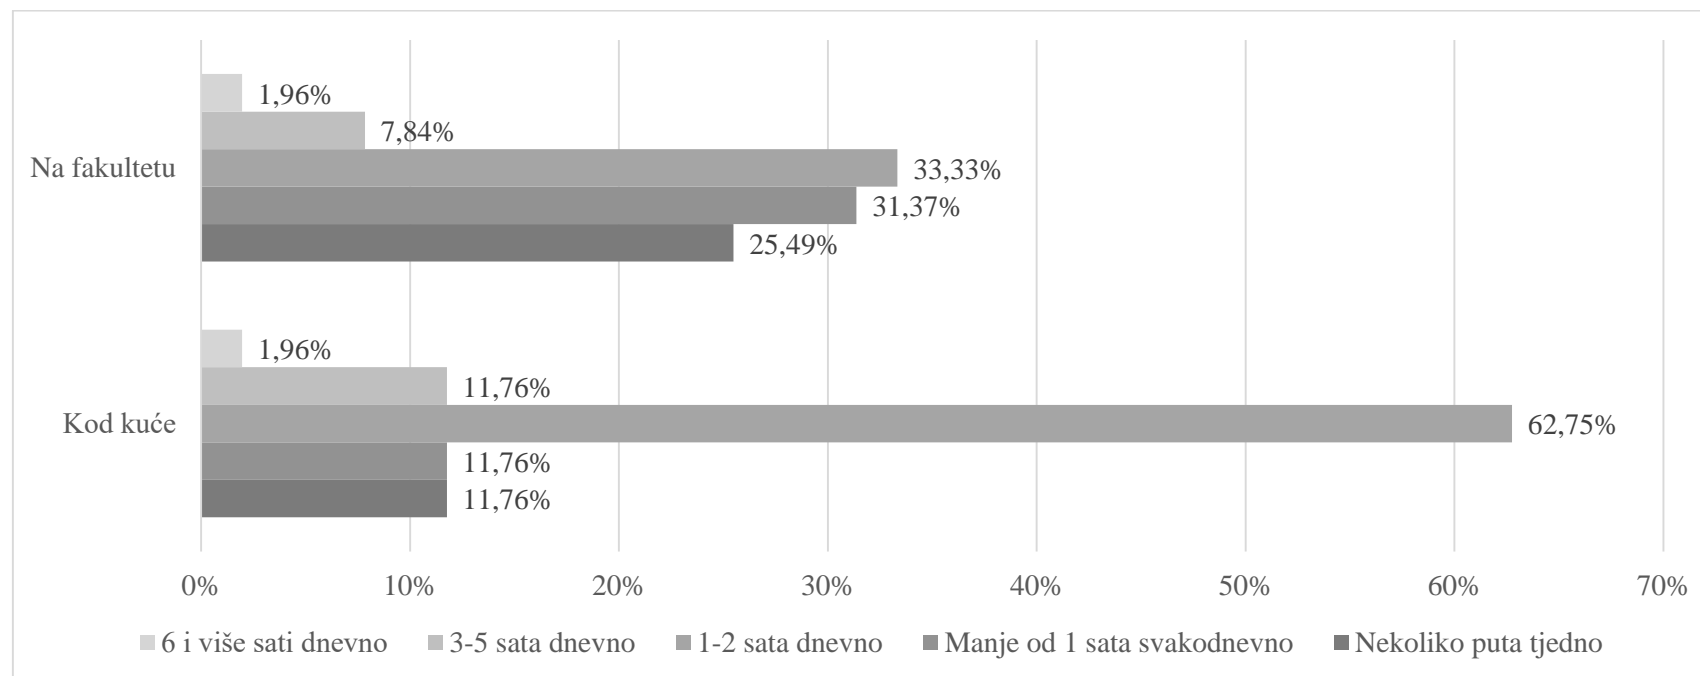


Slika 58. Grafički prikaz analize odgovora svih ispitanika u provedenom *drugom glavnom istraživanju* s obzirom na **dužinu korištenja** (u godinama) **Internet tehnologije** (N=51; uključuje *eksperimentalnu* i *kontrolnu* skupinu ispitanika)

Tablica 131. Analiza odgovora svih ispitanika u provedenom *drugom glavnom istraživanju* s obzirom na korištenje tehnologije e-učenja (N=51)

	Kod kuće		Na fakultetu	
	Frekv.	%	Frekv.	%
Nekoliko puta tjedno	6	11,76 %	13	25,49 %
Manje od 1 sata svakodnevno	6	11,76 %	16	31,37 %
1-2 sata dnevno	32	62,75 %	17	33,33 %
3-5 sata dnevno	6	11,76 %	4	7,84 %
6 i više sati dnevno	1	1,96 %	1	1,96 %
Ukupno	51	100 %	51	100 %

Frekv. = frekvencija odgovora



Slika 59. Grafički prikaz analize odgovora svih ispitanika u provedenom *drugom glavnom istraživanju* s obzirom na korištenje tehnologije e-učenja (N=51; uključuje *eksperimentalnu* i *kontrolnu* skupinu ispitanika)

U nastavku se navodi analiza rezultata za **drugu cjelinu anketnog upitnika**. Obuhvaćene su sljedeće skale: *Zadovoljstvo korištenja e-tečaja*, *Pregled nad tečajem / navigacija*, *Povratne informacije u e-tečaju*, *Zaokupljenost / uživljanje*, *Priprema / uputa za rad s e-tečajem*, *Primjerena težina e-tečaja*, *Motivacijski poticaji*, *Agregacija elemenata za motivacijske poticaje*, *Interakcija unutar e-tečaja*, *Postignuće učenja*, *Individualni proces učenja*, *Doživljaj e-tečaja*, *Evaluacija e-tečaja*. Druga cjelina sastoji se od ukupno **trinaest skala** koje se navode u tablici 132. i detaljnije unutar poglavlja **Prilozi**. (pogledati **prilog 3. i 4.**)

Tablica 132. Analiza skala **druge cjeline anketnog upitnika** u provedenom **drugom glavnom istraživanju** prije isključivanja neodgovarajućih čestica iz skala (N=51)

Naziv skale	Broj čestica	Prosječna vrijednost	Standardna devijacija	Raspon odgovora	Cronbach alpha koef.
Zadovoljstvo korištenja e-tečaja	9	3,02	1,02	1-5	,852
Pregled nad tečajem / navigacija	11	3,22	1,30	1-5	,912
Povratne informacije u e-tečaju	4	3,35	1,19	1-5	,912
Zaokupljenost / uživljanje	12	2,76	1,09	1-5	,835
Priprema / uputa za rad s e-tečajem	6	3,35	1,15	1-5	,666
Primjerena težina e-tečaja	7	3,14	1,34	1-5	,650
Motivacijski poticaji	4	3,35	0,96	1-5	,763
Agregacija elemenata za motivacijske poticaje	18	3,96	1,94	1-7	,935
Interakcija unutar e-tečaja	9	2,70	1,05	1-5	,894
Postignuće učenja	9	3,41	1,02	1-5	,867
Individualni proces učenja	7	3,78	1,19	1-5	,824
Doživljaj e-tečaja	9	3,41	1,20	1-5	,805
Evaluacija e-tečaja	28	2,96	1,18	1-5	,943

U tablicama 133. i 134 navode se rezultati za **treću cjelinu anketnog upitnika**. Obuhvaćena je skala pod nazivom *Evaluacija elemenata računalnih igara* koja se sastoji od 41 pitanja. Prvih 19 pitanja odnosi se na općenitu procjenu **mišljenja** ispitanika, dok se drugi dio od 22 pitanja odnosi na **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika.

Tablica 133. Analiza čestica **treće cjeline** *anketnog upitnika* (za čestice od 1 do 19) koja se odnosi na procjenu **mišljenja** ispitanika u provedenom *drugom glavnom istraživanju* (N=51)

Red. broj	Tvrdnja	Prosječna vrijednost	Standardna devijacija σ	Raspon odgovora
1	Bolje sam motiviran/a uz ljepše dizajnirano korisničko sučelje.	4,39	0,93	1-5
2	Zabavno mi je sakupljati bodove za svoja postignuća.	4,45	0,83	1-5
3	Trenutno stanje vlastitog postignuća treba biti jasno vidljivo.	4,51	0,83	1-5
4	Trenutna povratna informacija mi je poželjna.	4,51	0,67	3-5
5	Zabavno mi je otkriti sve što se, u sustavu za učenje, otkriti može.	4,13	0,74	2-5
6	Bolje pamtim kroz igru.	4,33	0,99	1-5
7	Zabavno mi je istraživati granice sustava za učenje.	3,76	1,03	1-5
8	Preferiram dinamičan sustav za učenje.	4,43	0,57	3-5
9	Preferiram jednostavno korisničko sučelje.	4,37	0,84	2-5
10	Preferiram biti vođen/a kroz sustav za učenje.	3,60	1,07	1-5
11	Stres negativno utječe na moj interes za temom.	3,88	1,25	1-5
12	Preferiram statičan oblik nastavnih sadržaja.	2,15	0,90	1-5
13	Preferiram surađivati s drugim studentima kroz timski rad.	3,15	0,98	1-5
14	Preferiram dijeliti znanje i pomagati drugima studentima.	3,60	0,72	2-5
15	Zabavno mi je natjecati se s drugim studentima.	3,60	0,96	1-5
16	Volim igrati računalne igre u slobodno vrijeme.	3,49	1,23	1-5
17	Volim igrati edukacijske računalne igre.	3,21	1,08	1-5
18	Preferiram se uspoređivati s boljim studentima.	3,21	1,20	1-5
19	Volim osjećaj svojeg napretka kroz sustav.	4,27	0,66	3-5

Tablica 134. Analiza čestica **treće cjeline** *anketnog upitnika* (za čestice od 20 do 41) koja se odnosi na **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika u provedenom *drugom glavnom istraživanju* (N=51)

Red. broj	U kolikoj mjeri smatrate da...	Prosječna vrijednost	Standardna devijacija σ	Raspon odgovora
20	... priča pomaže u boljem razumijevanju ciljeva učenja?	4,09	0,85	2-5
21	... individualni zadaci pomažu motiviranju studenata?	3,84	0,64	2-5
22	... individualni zadaci podižu interes za učenjem kod studenata?	3,78	0,67	2-5
23	... postepeno otkrivanje sadržaja pozitivno utječe na interes za temu?	3,80	1,04	1-5
24	... međusobna suradnja pozitivno utječe na Vaše učenje?	3,74	1,09	1-5
25	... natjecanje pozitivno utječe na Vaše učenje?	3,70	1,02	1-5
26	... vizualan dizajn pozitivno utječe na Vaše učenje?	4,31	0,86	1-5
27	... jednostavno grafičko sučelje pozitivno utječe na Vaše učenje?	4,27	0,87	1-5
28	... ambijent u sustavu pozitivno utječe na Vaše učenje?	4,21	0,83	1-5
29	... resursi u sustavu pozitivno utječu na Vaše učenje?	4,05	0,78	1-5
30	... pokazatelj preostalog vremena pozitivno utječe na Vaše učenje?	3,15	1,17	1-5
31	... nagrađivanje za postignuća pozitivno utječe na Vaše učenje?	4,27	0,66	3-5
32	... sakupljanje bodova pozitivno utječe na Vaše učenje?	4,27	0,72	3-5
33	... dodjela bedževa pozitivno utječe na Vaše učenje?	3,82	1,03	1-5
34	... dodjela certifikata pozitivno utječe na Vaše učenje?	4,25	0,89	2-5
35	... različite razine težine pozitivno utječe na Vaše učenje?	3,84	0,88	2-5
36	... trenutna povratna informacija pozitivno utječe na Vaše učenje?	4,31	0,70	2-5
37	... "Top 10" lista najboljih pozitivno utječe na Vaše učenje?	3,43	1,34	1-5
38	... evidencija aktivnosti pozitivno utječe na Vaše učenje?	3,66	0,93	1-5
39	... slobodan odabir materijala pozitivno utječe na Vaše učenje?	3,96	0,95	1-5
40	... raznolikost sadržaja pozitivno utječe na Vaše učenje?	4,05	0,81	1-5
41	... interaktivni materijali pozitivno utječu na Vaše učenje?	4,41	0,77	1-5

Tablica 135. Analiza rezultata *eksperimentalne* i *kontrolne* grupe u provedenom *drugom glavnom istraživanju* prije isključivanja neodgovarajućih čestica (N=51)

Naziv skale	Broj čestica	Cronbach alpha koef.	M _E	M _K	σ _E	σ _K	t	p
Zadovoljstvo korištenja e-tečaja	9	,852	3,04	3,01	1,07	0,97	0,31	0,7547
Pregled nad tečajem / navigacija	11	,912	3,19	3,25	1,35	1,25	0,53	0,5934
Povratne informacije u e-tečaju	4	,912	3,92	2,77	0,98	1,11	7,88	0,0001
Zaokupljenost / uživanje	12	,835	2,79	2,73	1,09	1,09	0,65	0,5119
Priprema / uputa za rad s e-tečajem	6	,666	3,43	3,00	1,19	1,10	3,30	0,0011
Primjerena težina e-tečaja	7	,650	3,08	3,21	1,41	1,27	0,86	0,3880
Motivacijski poticaji	4	,763	3,51	0,93	3,19	0,97	2,39	0,0174
Agregacija elemenata za motivacijske poticaje	18	,935	4,47	3,44	1,80	1,94	8,35	0,0001
Interakcija unutar e-tečaja	9	,894	2,82	2,57	1,00	1,09	2,61	0,0092
Postignuće učenja	9	,867	3,56	0,96	3,26	1,06	3,13	0,0018
Individualni proces učenja	7	,824	4,12	0,99	3,42	1,27	5,81	0,0001
Doživljaj e-tečaja	9	,805	3,43	3,39	1,30	1,10	0,31	0,7502
Evaluacija e-tečaja	28	,943	3,11	2,80	1,18	1,16	4,84	0,0001

M = prosječna vrijednost, σ = standardna devijacija, E = *eksperimentalna*, K = *kontrolna* grupa
t = odnos između prosječnih vrijednosti *eksperimentalne* i *kontrolne* grupe, te standardne pogreške razlike.

p = signifikantnost, tj. što je p vrijednost manja to je manja i empirijski utvrđena vjerojatnost odbacivanja istinite hipoteze i obratno. Precrtane p vrijednosti nisu statistički značajne.

6.3.4. Rasprava o rezultatima obrade podataka u *drugom glavnom istraživanju*

U ovom potpoglavlju prikazuju se rezultati *drugog glavnog istraživanja* koje je provedeno nad ispitanicima **Fakulteta organizacije i informatike**, koji su pohađali kolegij "Računalom posredovana komunikacija" i dobrovoljno sudjelovali u istraživanju. **Ukupno** je bilo **53** ispitanika koji su prema evidenciji na vježbama podijeljeni u dvije grupe. *Predtest* i *posttest* provjeru znanja u potpunosti je ispunilo **46** ispitanika. *Anketni upitnik* u cijelosti je ispunio **51** student. *Ekperimentalna* grupa bila je G1, dok je *kontrolna* grupa bila G2.

6.3.4.1. *Predtest* analiza rezultata u provedenom *drugom glavnom istraživanju*

Predtest je sadržavao ukupno 32 pitanja, od kojih je 26 pitanja imalo ponuđene odgovore, dok je unutar 6 pitanja odgovor trebalo vlastoručno upisivati. Pitanja su obuhvaćala općenite pojmove iz područja multimedije, poput pitanja o osnovnim elementima multimedije, hipertekstu, video zapisu, bojama, formatima i sl. Primjer pitanja iz *predtesta* kolegija "Računalom posredovana komunikacija" nalazi se u prilogu 2. ove doktorske disertacije (**Slika I**).

Unutar poglavlja 6.3.1. prikazan je tablični prikaz testiranja **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta* *eksperimentalne* (**G_E**) grupe (N=23) i *kontrolne* (**G_K**) grupe (N=23). Prosječna vrijednost bodova koju je *eksperimentalna* grupa postigla iznosi 21,91, uz standardnu devijaciju od 2,69. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 24. *Kontrolna* grupa ostvarila je prosječnu vrijednost bodova u iznosu od 20,91, uz standardnu devijaciju od 3,72. Najčešći iznos (Mod) sakupljenih bodova iznosi 18. Intermedijalna **vrijednost t** iznosi **1,04**. Izračunata **p vrijednost** iznosi **0,30** čime se može zaključiti kako između ispitanika *eksperimentalne* (**G_E**) grupe te ispitanika *kontrolne* (**G_K**) grupe **ne postoji statistički značajna razlika** obzirom na prosječne rezultate *predtesta*.

Na temelju rezultata *predtesta* zaključuje se kako se grupe statistički značajno ne razlikuju, te se ukazuje na mogućnost kojom se kroz provedbu *eksperimenta* može doći do statistički značajnih razlika. *Ekperimentalna* grupa izložena je *eksperimentalnom* e-tečaju, je *kontrolna* izložena klasičnom e-tečaju u kojima se nastavni sadržaji međusobno ne razlikuju.

6.3.4.2. Posttest analiza rezultata u provedenom drugom glavnom istraživanju

Posttest je sadržavao ukupno 31 pitanje. Struktura pitanja ista je kao u provedenom *predtestu*. Pitanja su obuhvaćala specifične pojmove koji su se nalazili unutar *gemificiranog* e-tečaja. Pitanja su obuhvaćala specifične pojmove iz područja multimedije, poput pitanja o frekvencijskom uzorkovanju, MIDI i WAV datotekama, komprimiranju podataka, formatima animacije i sl. U *posttest* provjeri znanja mjerila se usvojenost znanja polaznika obzirom na nastavne sadržaje *gemificiranog* i *klasičnog* e-tečaja. Primjer pitanja iz *posttesta*, kolegija "Računalom posredovana komunikacija", nalazi se u prilogu 2. ovog rada (**Slika J**).

Unutar poglavlja 6.3.2. prikazan je tablični prikaz testiranja **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta* **eksperimentalne** (**G_E**) grupe (N=23) i **kontrolne** (**G_K**) grupe (N=23). Prosječna vrijednost bodova koju je **eksperimentalna** grupa postigla iznosi 22,13 bodova uz standardnu devijaciju od 4,54. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 27. *Kontrolna* grupa ostvarila je prosječnu vrijednost bodova u iznosu od 16,61 uz standardnu devijaciju od 3,59. Najčešći iznos (Mod) sakupljenih bodova iznosi 20. Intermedijalna **vrijednost t** iznosi **4,57**. Izračunata **p vrijednost** iznosi **0,0001** čime se može zaključiti, uz mogućnost pogreške od 1%, kako između ispitanika **eksperimentalne** (**G_E**) grupe, te ispitanika **kontrolne** (**G_K**) grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*. **Eksperimentalna** grupa postigla je **bolji rezultat** za **33,23%**.

6.3.4.3. Unutarnja konzistentnost skala u provedenom drugom glavnom istraživanju

U ovom potpoglavlju nalazi se analiza **unutarnje konzistentnosti skala** iz provedenog **drugog glavnog istraživanja** koje je prikazano i u prilogu 7. Rezultat analize unutarnje konzistentnosti skala kao i pregled isključenih čestica moguće je vidjeti u tablicama 136. i 137.

Tablica 136. Pregled isključenih čestica iz skala i daljnje obrade u provedenom **drugom glavnom istraživanju**

Naziv skale	Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach alpha ako se čestica izbac
Zaokupljenost / uživljavanje	UZI_12R	-,004	,853
Priprema / uputa za rad s e-tečajem	UPT_7	,194	,695
Doživljaj e-tečaja	DOZ_2	,146	,824

Nakon isključivanja neodgovarajućih čestica *anketni upitnik* u drugom dijelu broji **130 česticu**. Kompletana analiza i opis unutarnje konzistentnosti nalazi se u **prilogu 7**.

Tablica 137. Usporedni prikaz analize anketnog upitnika prije i nakon isključivanja neodgovarajućih čestica iz skala (N=51)

Naziv skale	Analiza anketnog upitnika <u>prije</u> isključivanja neodgovarajućih čestica iz skala (N=51)				Analiza anketnog upitnika <u>nakon</u> isključivanja neodgovarajućih čestica iz skala (N=51)			
	Broj čestica	Prosječna vrijednost	Standardna devijacija σ	Cronbach alpha koef.	Broj čestica	Prosječna vrijednost	Standardna devijacija σ	Cronbach alpha koef.
Zadovoljstvo korištenja e-tečaja	9	3,02	1,02	,852	9	3,02	1,02	,852
Pregled nad tečajem / navigacija	11	3,22	1,30	,912	11	3,22	1,30	,912
Povratne informacije u e-tečaju	4	3,35	1,19	,912	4	3,35	1,19	,912
Zaokupljenost / uživanje	12	2,76	1,09	,835	11	2,75	1,11	,853
Priprema / uputa za rad s e-tečajem	6	3,35	1,15	,666	5	3,44	1,17	,695
Primjerna težina e-tečaja	7	3,14	1,34	,650	7	3,14	1,34	,650
Motivacijski poticaji	4	3,35	0,96	,763	4	3,35	0,96	,763
Agregacija elemenata za motivacijske poticaje	18	3,96	1,94	,935	18	3,96	1,94	,935
Interakcija unutar e-tečaja	9	2,70	1,05	,894	9	2,70	1,05	,894
Postignuće učenja	9	3,41	1,02	,867	9	3,41	1,02	,867
Individualni proces učenja	7	3,78	1,19	,824	7	3,78	1,19	,824
Doživljaj e-tečaja	9	3,41	1,20	,805	8	3,37	1,24	,824
Evaluacija e-tečaja	28	2,96	1,18	,943	28	2,96	1,18	,943

6.3.4.4. Razlika *eksperimentalne* i *kontrolne* skupine u odnosu na rezultate primjenom skala za procjenu

Tablica 138. Analiza rezultata *eksperimentalne* i *kontrolne* grupe u provedenom *drugom glavnom istraživanju* nakon korekcije svih skala (N=51)

Naziv skale	Broj čestica	Cronbach alpha koef.	M _E	M _K	σ _E	σ _K	t	p
Zadovoljstvo korištenja e-tečaja	9	,852	3,04	3,01	1,07	0,97	0,31	0,7547
Pregled nad tečajem / navigacija	11	,912	3,19	3,25	1,35	1,25	0,53	0,5931
Povratne informacije u e-tečaju	4	,912	3,92	2,7	0,98	1,11	7,88	0,0001
Zaokupljenost / uživanje	11	,853	2,79	2,70	1,11	1,11	0,93	0,3505
Priprema / uputa za rad s e-tečajem	5	,695	3,51	3,37	1,24	1,10	0,94	0,3477
Primjerena težina e-tečaja	7	,650	3,08	3,21	1,41	1,27	0,86	0,3880
Motivacijski poticaji	4	,763	3,51	3,19	0,93	0,97	2,39	0,0174
Agregacija elemenata za motivacijske poticaje	18	,935	4,47	3,44	1,80	1,94	8,35	0,0001
Interakcija unutar e-tečaja	9	,894	2,82	2,57	1,00	1,09	2,61	0,0092
Postignuće učenja	9	,867	3,56	0,96	3,26	1,06	3,13	0,0018
Individualni proces učenja	7	,824	4,12	0,99	3,42	1,27	5,81	0,0001
Doživljaj e-tečaja	8	,824	3,39	3,35	1,34	1,12	0,31	0,7516
Evaluacija e-tečaja	28	,943	3,11	2,80	1,18	1,16	4,84	0,0001

M = prosječna vrijednost, σ = standardna devijacija, E = *eksperimentalna*, K = *kontrolna* grupa
Precrtane p vrijednosti nisu statistički značajne.

Iz tablice 138. vidljivo je kako u skalama *Zadovoljstvo korištenja e-tečaja*, *Pregled nad tečajem / navigacija*, *Zaokupljenost / uživanje*, *Priprema / uputa za rad s e-tečajem*, *Primjerena težina e-tečaja* i *Doživljaj e-tečaja* ne postoji statistički značajna razlika između *eksperimentalne* i *kontrolne* grupe ispitanika. Skupni odgovori u svim ostalim slučajevima statistički se značajno razlikuju. Nastavni sadržaji oba e-tečaja bili su identični.

Tablica 139. Analiza čestica **treće cjeline** *anketnog upitnika* (za čestice od 1 do 19) koja se odnosi na procjenu **mišljenja** ispitanika u provedenom *drugom glavnom istraživanju* (N=51)

Red. broj	Tvrdnja	M _E	M _K	σ _E	σ _K	t	p
1	Bolje sam motiviran/a uz ljepše dizajnirano korisničko sučelje.	4,42	4,36	0,95	0,95	0,23	0,8134
2	Zabavno mi je sakupljati bodove za svoja postignuća.	4,50	4,40	0,99	0,65	0,42	0,6724
3	Trenutno stanje vlastitog postignuća treba biti jasno vidljivo.	4,46	4,56	1,03	0,58	0,41	0,6776
4	Trenutna povratna informacija mi je poželjna.	4,58	4,44	0,64	0,71	0,72	0,4742
5	Zabavno mi je otkriti sve što se, u sustavu za učenje, otkriti može.	4,19	4,08	0,85	0,64	0,53	0,5974
6	Bolje pamtim kroz igru.	4,46	4,20	1,03	0,96	0,93	0,3524
7	Zabavno mi je istraživati granice sustava za učenje.	4,04	3,48	1,04	0,96	1,98	0,0522
8	Preferiram dinamičan sustav za učenje.	4,50	4,36	0,58	0,57	0,86	0,3898
9	Preferiram jednostavno korisničko sučelje.	4,50	4,24	0,81	0,88	1,09	0,2779
10	Preferiram biti vođen/a kroz sustav za učenje.	3,65	3,56	1,06	1,12	0,30	0,7595
11	Stres negativno utječe na moj interes za temom.	3,69	4,08	1,38	1,12	1,10	0,2761
12	Preferiram statičan oblik nastavnih sadržaja.	2,31	2,00	0,93	0,87	1,22	0,2272
13	Preferiram surađivati s drugim studentima kroz timski rad.	3,19	3,12	1,02	0,97	0,25	0,7967
14	Preferiram dijeliti znanje i pomagati drugima studentima.	3,50	3,72	0,71	0,74	1,08	0,2820
15	Zabavno mi je natjecati se s drugim studentima.	3,73	3,48	0,96	0,96	0,93	0,3567
16	Volim igrati računalne igre u slobodno vrijeme.	3,50	3,48	1,39	1,08	0,05	0,9547
17	Volim igrati edukacijske računalne igre.	3,31	3,12	1,19	0,97	0,61	0,5414
18	Preferiram se uspoređivati s boljim studentima.	3,23	3,20	1,34	1,08	0,09	0,9285
19	Volim osjećaj svojeg napretka kroz sustav.	4,35	4,20	0,63	0,71	0,78	0,4387

M = prosječna vrijednost, **σ** = standardna devijacija, **E** = *eksperimentalna*, **K** = *kontrolna* grupa
p = signifikantnost, tj. što je p vrijednost manja to je manja i empirijski utvrđena vjerojatnost odbacivanja istinite hipoteze i obratno. Precrtane p vrijednosti nisu statistički značajne.

Tablica 140. Analiza čestica treće cjeline anketnog upitnika (za čestice od 20 do 41) koja se odnosi na **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika u provedenom *drugom glavnom istraživanju* (N=51)

Red. broj	U kolikoj mjeri smatrate da...	M_E	M_K	σ_E	σ_K	t	p
20	... priča pomaže u boljem razumijevanju ciljeva učenja?	4,00	4,20	0,80	0,91	0,83	0,4089
21	... individualni zadaci pomažu motiviranju studenata?	3,69	4,00	0,68	0,58	1,73	0,0882
22	... individualni zadaci podižu interes za učenjem kod studenata?	3,62	3,96	0,64	0,68	1,87	0,0669
23	... postepeno otkrivanje sadržaja pozitivno utječe na interes za temu?	3,92	3,68	1,02	1,07	0,83	0,4094
24	... međusobna suradnja pozitivno utječe na Vaše učenje?	3,73	3,76	1,08	1,13	0,09	0,9250
25	... natjecanje pozitivno utječe na Vaše učenje?	3,92	3,48	1,06	0,96	1,56	0,1241
26	... vizualan dizajn pozitivno utječe na Vaše učenje?	4,31	4,32	1,09	0,56	0,05	0,9599
27	... jednostavno grafičko sučelje pozitivno utječe na Vaše učenje?	4,31	4,24	1,01	0,72	0,27	0,7852
28	... ambijent u sustavu pozitivno utječe na Vaše učenje?	4,12	4,32	0,99	0,63	0,87	0,3854
29	... resursi u sustavu pozitivno utječu na Vaše učenje?	4,12	4,00	0,91	0,65	0,52	0,6048
30	... pokazatelj preostalog vremena pozitivno utječe na Vaše učenje?	2,92	3,40	1,23	1,08	1,46	0,1483
31	... nagrađivanje za postignuća pozitivno utječe na Vaše učenje?	4,35	4,20	0,69	0,65	0,78	0,4387
32	... sakupljanje bodova pozitivno utječe na Vaše učenje?	4,31	4,24	0,74	0,72	0,33	0,7420
33	... dodjela bedževa pozitivno utječe na Vaše učenje?	4,15	3,48	0,83	1,12	2,44	0,0183
34	... dodjela certifikata pozitivno utječe na Vaše učenje?	4,27	4,24	0,78	1,01	0,11	0,9081
35	... različite razine težine pozitivno utječe na Vaše učenje?	4,04	3,64	0,87	0,86	1,64	0,1067
36	... trenutna povratna informacija pozitivno utječe na Vaše učenje?	4,35	4,28	0,80	0,61	0,33	0,7420
37	... "Top 10" lista najboljih pozitivno utječe na Vaše učenje?	3,58	3,28	1,36	1,34	0,78	0,4363
38	... evidencija aktivnosti pozitivno utječe na Vaše učenje?	3,81	3,52	0,85	1,00	1,10	0,2743
39	... slobodan odabir materijala pozitivno utječe na Vaše učenje?	3,92	4,00	1,06	0,87	0,28	0,7777
40	... raznolikost sadržaja pozitivno utječe na Vaše učenje?	4,04	4,08	0,87	0,76	0,18	0,8569
41	... interaktivni materijali pozitivno utječu na Vaše učenje?	4,35	4,48	0,89	0,65	0,60	0,5451

p = signifikantnost, precrtane p vrijednosti nisu statistički značajne.

Iz tablica 139. i 140. koje analiziraju skalu **trećeg dijela** *anketnog upitnika*, koji se odnosi na procjenu **mišljenja** ispitanika i **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika u provedenom *drugom glavnom istraživanju* (N=51), može se zaključiti kako obje grupe ispitanika (*eksperimentalna* i *kontrolna*) imaju podjednake odgovore. Od ukupno 41 pitanja ili tvrdnje samo jedna tvrdnja: "...**dodjela bedževa pozitivno utječe na Vaše učenje?**" statistički se razlikuje između grupa.

Tablica 141. Testiranje **statističke značajnosti razlike** metodom t-testa između prosječnih rezultata odgovora na sve čestice **treće cjeline** *anketnog upitnika* (N=51)

Ispitanici	Broj ispitanika	Broj čestica	Prosječna vrijednost odgovora M	Standardna devijacija σ	t	p
G_E	26	41	3,94	0,49	0,67	0,5014
G_K	25	41	3,87	0,51		

G_E = *eksperimentalna* grupa, **G_K** = *kontrolna* grupa

Tablica 141. prikazuje izračun statističke značajnosti na temelju prosječnih rezultata odgovora na čestice **treće cjeline** *anketnog upitnika* (za čestice od 1 do 41), prema kojoj se može zaključiti kako između *eksperimentalne* (**G_E**) i *kontrolne* (**G_K**) grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate upitnika. Eksperiment niti u ovom slučaju nije utjecao na mišljenje ispitanika *eksperimentalne* grupe. Prosječna vrijednost odgovora obje grupe prelazi vrijednost 3,85 od maksimalne vrijednosti 5, prema kojoj se može zaključiti kako ispitanici imaju **pozitivan stav** o **motivacijskim** elementima iz računalnih igara.

6.3.4.5. Zaključci imajući u vidu hipoteze i rezultate *drugog glavnog istraživanja*

Prva hipoteza ove disertacije navedena je unutar poglavlja 5.2. te glasi:

H1. E-tečaj dizajniran uz primjenu elemenata računalnih igara **pozitivno utječe na zainteresiranost** polaznika tog tečaja u odnosu na tečaj istog obrazovnog sadržaja, ali bez prisutnosti elemenata računalnih igara.

Kako bi se potvrdila hipoteza H1, provedeno je *drugo glavno istraživanje* u kojemu je prisustvovao 51 ispitanik. Mišljenje je prikupljeno putem *anketnog upitnika* koji se sastoji od tri dijela, gdje se prvi dio odnosi na **deskriptivne pokazatelje** grupe ispitanika, drugi dio na **zadovoljstvo, motivaciju, interakciju i proces učenja**, a treći dio na zainteresiranost i općenitu procjenu **mišljenja** i **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika.

Tvrđnja hipoteze H1 je potvrđena. Odluka se temelji na odgovorima iz *anketnog upitnika* i temeljem objektivnih pokazatelja studentskih aktivnosti unutar Moodle e-tečaja.

Nakon izbacivanja neodgovarajućih čestica iz drugog dijela, *anketni upitnik* broji 130 čestica koje su podijeljene u 13 skala. Iz analize skala može se zaključiti kako *eksperimentalna* grupa u odnosu na *kontrolnu* grupu ispitanika ima veće prosječne vrijednosti odgovora. Izrazita statistička značajnost ne postoji u skalama *Zadovoljstvo korištenja e-tečaja*, *Pregled nad tečajem / navigacija*, *Zaokupljenost / uživljanje*, *Priprema / uputa za rad s e-tečajem*, *Primjerena težina e-tečaja* i *Doživljaj e-tečaja*, za razliku od predistraživanja gdje statistička značajnost ne postoji samo u skali *Primjerena težina e-tečaja*. Uzorak ispitanika je 51.

Tablica 142. Testiranje statističke značajnosti razlike metodom t-testa između prosječnih rezultata odgovora **druge cjeline** nakon korekcije *anketnog upitnika* (N=51)

Ispitanici	Broj ispitanika	Broj skala	Prosječna vrijednost odgovora M	Standardna devijacija σ	t	p
G_E	26	13	3,42	0,50	2,54	0,0178
G_K	25	13	2,74	0,82		

G_E = *eksperimentalna* grupa, **G_K** = *kontrolna* grupa

Tablica 142. prikazuje izračun statističke značajnosti na temelju prosječnih rezultata odgovora **druge cjeline** *anketnog upitnika*. Izračunata p vrijednost navodi mogući zaključak, uz mogućnost pogreške od 1%, kako između *eksperimentalne* (**G_E**) i *kontrolne* (**G_K**) grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate odgovora svih skala koje se nalaze unutar drugog dijela *anketnog upitnika*.

Treći dio *anketnog upitnika* sastoji se od jedne skale koja broji 41 česticu. *Anketni upitnik* evidentira **mišljenja** ispitanika i **utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika. U *anketnom upitniku*, gdje je raspon mogućih odgovora od 1-5, vidljivo je kako je prosječna vrijednost odgovora za *eksperimentalnu* grupu iznosila 3,95, a za *kontrolnu* grupu 3,87., iz čega se može zaključiti kako ispitanici imaju pozitivan stav o **motivacijskim elementima** iz računalnih igara. Niti u ovom slučaju između grupa **ne postoji statistički značajna razlika**, što bi značilo kako eksperiment nije utjecao na mišljenje polaznika o motivirajućim elementima. Obje grupe **imaju pozitivno mišljenje** o elementima računalnih igara u obrazovnom sustavu, što ide u prilog hipotezi H1.

U nastavku disertacije navode se izvještaji o studentskim aktivnostima koji su generirani na temelju *log* zapisa iz Moodle sustava, te ujedno predstavljaju i završni dio koji se uzima u obzir prilikom donošenja zaključka o prihvaćanju ili odbacivanju **hipoteze H1** i **podhipoteze H1.1**.

Tablica 143. Izvještaj o aktivnosti *eksperimentalne* (N=25) i *kontrolne* (N=25) grupe polaznika

Naziv aktivnosti (obrazovna tema)	Aktivnost <i>eksperimentalne</i> grupe			Aktivnost <i>kontrolne</i> grupe		
	Ukupno	Prosjek	SD	Ukupno	Prosjek	SD
Check lista	238	9,52	9,29			
Dobrodošli u sustav	140	5,60	3,03			
Objašnjenje elemenata i načina s radom u e-tečaju	76	3,04	1,34			
Chat - G	79	3,16	1,25			
Ishodi učenja	71	2,84	1,14	17	0,68	0,80
Forum	292	11,68	8,63	58	2,32	1,77
Popis pojmova	158	6,32	6,46			
Multimedijalni elementi	129	5,16	9,07	34	1,36	1,15
Nastavno poglavlje 1a: Tekst	142	5,68	9,18	25	1,00	1,12
Nastavno poglavlje 1b: Grafika	141	5,64	9,59	22	0,88	1,13
Nastavno poglavlje 1c: Zvuk	94	3,76	1,85	14	0,56	0,71
Interaktivno ponavljanje: +< 1 >+	716	28,6	24,35			
Interaktivno ponavljanje: RPK A	272	10,9	13,87			
Bonus nastavni sadržaj: Boja	111	4,44	11,25	16	0,64	0,76
Bonus nastavni sadržaj: Ostali pojmovi	109	4,36	10,25	19	0,76	1,01
Nastavno poglavlje 2a: Video	125	5	11,35	13	0,52	0,71
Nastavno poglavlje 2b: Animacija	122	4,88	10,96	18	0,72	0,89
Nastavno poglavlje 2c: Hipermedija i hipertekst	155	6,2	17,73	13	0,52	0,92
Interaktivno ponavljanje: +< 2 >+	531	21,2	20,22			
Interaktivno ponavljanje: RPK B	203	8,12	11,77			
Bonus nastavni sadržaj: Primjena teksta na Webu	102	4,08	10,30	18	0,72	0,94
Bonus nastavni sadržaj: Grafika za Web	103	4,12	10,73	21	0,84	1,14
Bonus nastavni sadržaj: Primjena zvuka na Webu	106	4,24	11,12	13	0,52	0,71
Bonus nastavni sadržaj: Primjena videa na Webu	112	4,48	12,90	11	0,44	0,58
Bonus nastavni sadržaj: Primjena animacije na Webu	187	7,48	27,86	14	0,56	0,87
Ukupna aktivnost polaznika e-tečaja	4514	7,22		326	0,82	

Tablica 143. navodi popis aktivnosti koje su namijenjene *drugom glavnom istraživanju* ove disertacije. Prazan prostor koji je vidljiv unutar *kontrolne* grupe, navodi da ispitanici koji su koristili *kontrolni* e-tečaj nisu mogli pristupiti navedenim aktivnostima.

Razlog tome je taj što su navedene aktivnosti vezane uz osnovne principe računalnih igara koji su objašnjeni unutar teorijskog dijela ove disertacije. Aktivnost polaznika, koja se prikazuje u zadnjem retku tablice 143., pokazuje ukupan broj pristupa pojedinoj aktivnosti, te za *eksperimentalnu* grupu iznosi **4514**, dok za *kontrolnu* grupu iznosi **326**. Studenti *eksperimentalne* grupe su nastavnim materijalima prosječno pristupali **7,22** puta, dok su studenti *kontrolne* grupe nastavnim materijalima prosječno pristupali **0,82** puta.

Vidljivo je kako je *eksperimentalna* grupa ispitanika pokazala značajno veći interes za općenitim elementima sustava, kao što su cjeline pod nazivima "*Forum*" i "*Ishodi učenja*". U slučaju *drugog glavnog istraživanja*, bonus nastavni materijali bili su uključeni u oba e-tečaja. *Eksperimentalna* grupa ispitanika je iznimno dobro iskoristila elemente za provjeru znanja unutar kojih je vrlo važnu ulogu imala trenutna povratna informacija o korektno riješenim zadacima. Vidljivo je kako je zbirni broj **pristupa nastavnim poglavljima** nešto manji u odnosu na broj **pristupa elementima za ponavljanje** znanja koji se vode pod nazivom "*Interaktivno ponavljanje*".

Također, kao i u ranijim istraživanjima, *predistraživanju* i *prvom glavnom istraživanju*, veći interes za bonus i nastavnim materijalima je kod *eksperimentalne* grupe ispitanika gotovo konstantan, kao i vrlo nizak interes kod *kontrolne* grupe ispitanika

Iz navedenih pokazatelja može se zaključiti kako je *eksperimentalna* grupa imala znatno veću motiviranost, što je vidljivo kroz veću evidentiranu aktivnost unutar Moodle e-tečaja s obzirom na korištenje dostupnih **nastavnih i nenastavnih materijala**, čime se **prihvća tvrdnja hipoteze H1**.

Pretpostavke autora koje se navode unutar ove doktorske disertacije (Chou, 2016.; Lombriser, 2015.; Adeel, 2014.; Kovacova i Vackova, 2015. i dr.) govore kako elementi računalnih igara pozitivno utječu na motivaciju studenata, U skladu s time, u nastavku ove disertacije prikazat će se rezultati iz *drugog glavnog istraživanja* koji utječu na potvrđivanje hipoteze H1.1.

Prva podhipoteza ove disertacije glasi:

H1.1. Elementi računalnih igara, koji su uključeni u *eksperimentalni* e-tečaj, **pozitivno utječu** na **veće korištenje nastavnih materijala**, u usporedbi s klasičnim e-tečajem koji sadrži identične nastavne materijale, bez prisutnosti elemenata računalnih igara.

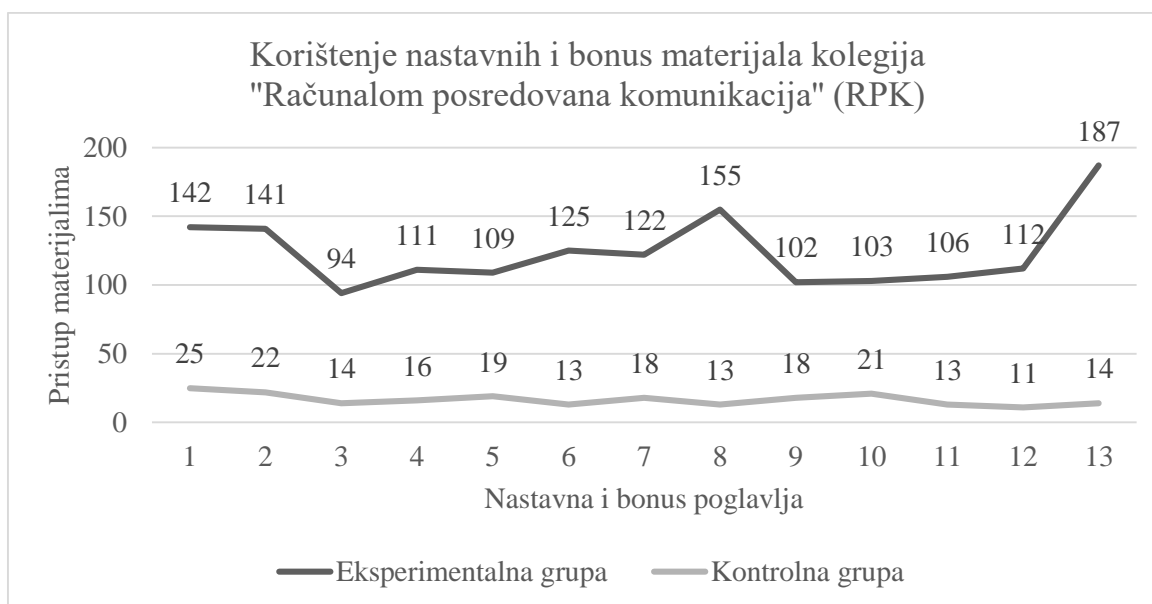
Studenti u okviru kolegija "Računalom posredovana komunikacija", za razliku od studenata koji su bili uključeni u *predistraživanje* ovog doktorskog rada na kolegiju "3D modeliranje", ranije su koristili e-tečaj za potrebe informiranja i pristupanja nastavnim materijalima. Navedeni slučaj prisutan je i unutar *prvog glavnog istraživanja*. Nakon uvodnog predavanja i objašnjenja toka istraživanja, provedena je *predtest* provjera znanja, te su studenti uključeni u *kontrolni* ili *eksperimentalni* e-tečaj s obzirom na prosječan broj bodova pojedine grupe. Ranije, u **poglavlju 5.5.**, objašnjeno je kako su studenti jedne grupe na vježbama ujedno i jedna grupa u istraživanju, što znači kako su unutar kolegija "Računalom posredovana komunikacija" postojale ukupno **dvije grupe**, od kojih je jedna bila *kontrolna* i jedna *eksperimentalna*. U provedenom *drugom glavnom istraživanju* unutar kolegija "Računalom posredovana komunikacija", korišteno je ukupno 13 nastavnih i bonus materijala koje su studenti imali na raspolaganju minimalno 14 dana. Izdvojeni nastavni materijali nalaze se u tablici 144. ovog poglavlja.

Tvrđnja podhipoteze H1.1 je potvrđena. Odluka se temelji na tabličnoj i grafičkoj analizi objektivnih pokazatelja koji su generirani pomoću *log* zapisa iz Moodle sustava, te se navode u nastavku ove doktorske disertacije unutar tablice 144. i slike 59.

Tablica 144. Usporedni prikaz korištenja nastavnih i bonus materijala u kolegiju "RPK"

Nastavna poglavlja kolegija "Računalom posredovana komunikacija"	Eksperimentalna grupa	Kontrolna grupa
1. Nastavno poglavlje 1a: Tekst	142	25
2. Nastavno poglavlje 1b: Grafika	141	22
3. Nastavno poglavlje 1c: Zvuk	94	14
4. Bonus nastavni sadržaj: Boja	111	16
5. Bonus nastavni sadržaj: Ostali pojmovi	109	19
6. Nastavno poglavlje 2a: Video	125	13
7. Nastavno poglavlje 2b: Animacija	122	18
8. Nastavno poglavlje 2c: Hipermedija i hipertekst	155	13
9. Bonus nastavni sadržaj: Primjena teksta na Webu	102	18
10. Bonus nastavni sadržaj: Grafika za Web	103	21
11. Bonus nastavni sadržaj: Primjena zvuka na Webu	106	13
12. Bonus nastavni sadržaj: Primjena videa na Webu	112	11
13. Bonus nastavni sadržaj: Primjena animacije na Webu	187	14
Ukupna aktivnost nad nastavnim i bonus materijalima	1609	217

Tablica 144. prikazuje usporedni prikaz korištenja nastavnih i bonus materijala koji su generirani na temelju *log* zapisa iz Moodle e-tečaja koji je korišten u *drugom glavnom istraživanju*. Rezultati *log* zapisa u nastavku ovog rada prikazuju se i kroz sliku 60.



Slika 60. Grafički prikaz korištenja nastavnih i bonus materijala u kolegiju "RPK"

- ❖ **Kontrolni** e-tečaj osmišljen je kao i ranija dva istraživanja, te sadrži mogućnosti korištenja avatara, foruma, te mogućnost nelinearnog pristupanja nastavnim materijalima. Tablica 144. i slika 60. prikazuju konstantan i nizak interes za nastavnim materijalima. Izgled e-tečaja koji je vizualno sličan kontrolnom e-tečaju iz ovog istraživanja prikazan je na **slici 26**. U provedenom **predistraživanju**, kontrolni e-tečaj **drugog glavnog istraživanja** nije uključivao **niti jedan dodatni element** računalnih igara, osim već spomenutog avatara, foruma i nelinearnog pristupa sadržajima.
- ❖ **Eksperimentalni** e-tečaj sadrži **elemente računalnih igara** koji su prikazani unutar tablice 26. (poglavlje 4.3.), te su služili kao potpora nastavnim materijalima koji se navode u tablici 144. Studentska aktivnost je najveća u poglavljima pod nazivom: "*Hipermedija i hipertekst*" i "*Primjena animacije na Webu*". Cjelokupna aktivnost **eksperimentalne** grupe ispitanika može se objasniti **visokim stupnjem interesa** za nastavnim materijalima i **visokim stupnjem interesa** za drugačijem pristupu obrazovnim sadržajima. Sličan pokazatelj već je viđen u okviru **predistraživanja**, kao i kod **prvog glavnog istraživanja**. Najveća razlika između **kontrolne** i **eksperimentalne** skupine ispitanika uočena je na kraju druge cjeline unutar poglavlja pod nazivom: "*Primjena animacije na Webu*". Razlika u aktivnosti je **13 puta** veća u korist **eksperimentalne** skupine ispitanika. Interes za nastavnim materijalima veći je kod **eksperimentalne** grupe ispitanika, isto kao i u ranije provedenim istraživanjima. Objašnjenje ovakvih rezultata pripisuje se vizualno privlačnijem dizajnu e-tečaja koji je upotpunjen s elementima računalnih igara prikazanim unutar tablice 24.

S obzirom na objektivne rezultate generirane temeljem *log* zapisa o aktivnostima nad nastavnim i bonus materijalima iz Moodle sustava koji je korišten u **drugom glavnom istraživanju**, kao i u slučaju provedenog **predistraživanja** i **prvog glavnog istraživanja**, može se zaključiti kako elementi računalnih igara, koji su uključeni u *eksperimentalni* e-tečaj, **utječu na veće korištenje nastavnih materijala** čime se potvrđuje podhipoteza H1.1 ove doktorske disertacije.

Druga hipoteza ove disertacije navedena je unutar poglavlja 5.2. te glasi:

H2. E-tečaj dizajniran uz primjenu elemenata računalnih igara omogućuje **postizanje boljih rezultata** polaznika u odnosu na tradicionalne pristupe e-učenju, imajući u vidu razinu **stečenog znanja** iz određenog nastavnog sadržaja.

Kako bi se potvrdila hipoteza H2, potrebno je osigurati uvjete za testiranje razine stečenog znanja iz određenog nastavnog sadržaja što je postignuto kroz tri koraka koji su opisani u *predistraživanju*.

- U **prvom koraku** studenti su prema evidenciji na vježbama podijeljeni u dvije grupe.
- U **drugom koraku** testirana je statistička razlika između grupa. Nakon testiranja **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta* **ispitanika eksperimentalne (G_E; N=23)** i **kontrolne (G_K; N=23)** grupe, utvrđeno je kako **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta*, te se ukazuje na mogućnost dolaska do statistički značajnih razlika u *eksperimentalnom* sustavu.

Tablica 145. Usporedni prikaz testiranja **statističke značajnosti razlike** metodom t-testa između rezultata *predtesta* i rezultata *posttesta* kod **svih ispitanika eksperimentalne (G_E; N=23)** i **kontrolne (G_K; N=23)** grupe

Testiranje	Ispitanici	Broj ispitanika	Prosječna vrijednost bodova M	Standardna devijacija σ	t	p
<i>Predtest</i>	G _E	23	21,91	2,70	1,04	0,3029
	G _K	23	20,91	3,73		
<i>Posttest</i>	G _E	23	22,13	4,55	4,57	0,0001
	G _K	23	16,61	3,59		

- U **trećem koraku** polaznici oba e-tečaja nastavne su materijale proučavali isključivo kroz e-tečaj. Izračun je vidljiv u tablici 145. Teme tečaja nisu spominjane na predavanjima niti na laboratorijskim vježbama. Korištenje e-tečajeva trajalo je minimalno 14 dana nakon kojih slijedi testiranje stečenog znanja primjenom *posttest* provjere znanja.

Provodi se testiranje **statističke značajnosti razlike** metodom t-testa između rezultata *posttesta* ispitanika *eksperimentalne* (G_E ; $N=23$) i *kontrolne* (G_K ; $N=23$) grupe, gdje izračunata **p vrijednost** iznosi **0,0001** prema kojoj se može zaključiti, uz mogućnost pogreške od 1%, kako između ispitanika *eksperimentalne* grupe te ispitanika *kontrolne* grupe **postoji statistički značajna razlika** s obzirom na prosječne rezultate *posttesta*. *Eksperimentalna* grupa postigla je bolji rezultat za **33,23%** čime je **prihvaćena tvrdnja hipoteze H2**.

Druga podhipoteza ove disertacije glasi:

H2.1. *Eksperimentalna* grupa ispitanika, koja je u *predtest* provjeri znanja ostvarila **minimalno 50%** bodova, postići će **statistički značajnije** rezultate u odnosu na *kontrolnu* grupu ispitanika, koja je u *predtest* provjeri znanja ostvarila **minimalno 50%** bodova, s obzirom na ostvarene bodove u *posttest* provjeri znanja.

Za potrebe potvrđivanja podhipoteze H2.1, napravljena je dodatna analiza bodova samo nad ispitanicima koji su zadovoljili dodatni uvjet, koji je vezan za ostvarivanje **minimalno 50% ukupnih bodova** u provedenom *predtestu drugog glavnog istraživanja*. Od ukupnog broja ispitanika, njih 51 je zadovoljilo navedeni uvjet. Provedena je analiza *posttest* provjere znanja temeljem ukupno ostvarenih bodova (ukupno 31 pitanja), koja je detaljno prikazana u **poglavlju 6.3.2**. Rezultat skraćene analize nalazi se u tablici 146. u nastavku ove doktorske disertacije.

Tvrdnja podhipoteze H2.1 je potvrđena. Odluka se temelji na analizi *posttest* provjere znanja koja se, kao i u provedenom *predistraživanju* i *prvom glavnom istraživanju*, u skraćenom obliku navodi u nastavku ove doktorske disertacije.

Tablica 146. Skraćeni prikaz analize odgovora iz provedenog *posttesta* u drugom glavnom istraživanju

	Ukupni rezultat (uk. broj pitanja = 32)	
	Eksp.	Kont.
Grupa ispitanika		
Prosjek bodova	22,39	18,81
Stand. devijacija	6,06	4,06
Broj ispitanika	23	21
t vrijednost	2,28	
p vrijednost	0,027	

*Eksp. = *eksperimentalna* grupa, *Kont. = *kontrolna* grupa

Unutar tablice 146. navode se bodovi za sva pitanja *posttest* provjere znanja (ukupno 31 pitanja), a koja su bila *eksperimentalnoj* i *kontrolnoj* grupi na raspolaganju te je nad njima provedena t-test analiza. Izračunata **t vrijednost iznosi 2.28**, dok je **p vrijednost 0.027**, čime se zaključuje kako između ispitanika *eksperimentalne* (N=23) i *kontrolne* (N=21) grupe ispitanika **postoji statistički značajna razlika**. Prosječan broj bodova u *posttest* provjeri znanja u *eksperimentalnoj* grupi ispitanika bio je za **19,03%** veći u odnosu na *kontrolnu* grupu ispitanika.

S obzirom na rezultat prosječnih bodova *posttest* provjere znanja u okviru ***drugog glavnog istraživanja***, gdje su analizirani rezultati samo onih ispitanika koji su ostvarili **minimalno 50% od ukupnih** bodova, zaključuje se kako između ispitanika *eksperimentalne* (N=23) i *kontrolne* (N=21) grupe ispitanika **postoji statistički značajna razlika** čime se i potvrđuje podhipoteza H2.1 ove doktorske disertacije.

7. DISKUSIJA

U ovom se poglavlju navode rezultati empirijskog istraživanja koje je provedeno u sklopu ove disertacije. Daje se osvrt na ostvarena postignuća u e-tečajevima svih polaznika *eksperimentalne* i *kontrolne* grupe. Komentira se izvještaj o aktivnosti studenata (*log*) koji su bili uključeni u *eksperimentalni* i *kontrolni* e-tečaj u sva tri istraživanja. Navodi se nekoliko doktorskih disertacija koje su objavljene 2015. i 2016. godine, a čiji predmet istraživanja su elementi računalnih igara u obrazovanju.

7.1. PROBLEMI I MOTIVACIJA ZA PROVOĐENJE ISTRAŽIVANJA

Istraživanje u okviru ovoga dokorskog rada započelo je online **anketiranjem 43 nastavnika** koji koriste **Moodle LMS** u svakodnevnoj nastavi u radu sa studentima. Prikupljene su informacije o inicijalnim verzijama Moodle sustava koje se koriste u nastavi na dvije visokoškolske ustanove. Analizirana je stručna i znanstvena literatura koja obuhvaća računalne igre i njihovo korištenje unutar obrazovnog, ali i općenitog zabavnog sektora. Uočeno je kako obrazovni sustavi imaju **zastarjelo korisničko sučelje**. Elementi koji se mogu pronaći u računalnim igrama, a doprinose **zabavi** korisnicima sustava za e-učenje, gotovo da se i **ne koriste**. U tekstu koji slijedi spominju se tri glavna čimbenika koji su povezani s e-učenjem.

- **Administratori** na obrazovnim institucijama postavljaju sustav koji je u određenom trenutku **najstabilniji** s obzirom na ostale programske i sklopovske čimbenike. Administratori su **tehničari** ili **inženjeri** koji nemaju uvid u pedagoške i psihološke zahtjeve korisnika e-tečaja, niti u popratnu dokumentaciju o intrinzičnoj ili ekstrinzičnoj motivaciji.
- **Nastavnici** imaju **osiguran virtualan prostor** unutar kojeg samostalno ili uz pomoć asistenta **kreiraju** sadržaj za e-tečaj koji prati nastavne cjeline kolegija. Svaki virtualni prostor unutar LMS sustava ima **identičnu strukturu**, gdje nastavnik može mijenjati samo elemente koje dodaje kroz unaprijed određene module. Veće **promjene** u pogledu vanjskih dodataka **nisu moguće**, ako administratori ne odluče da je vanjski dodatak nužan dio cjelokupnog sustava za e-učenje.
- **Studenti** često koriste LMS sustav kao **primarni izvor** informacija za učenje i pripremu za nadolazeće provjere znanja. E-tečaj se dnevno mijenja po pitanju raznih informacija, komunikacijskih aktivnosti, evidencije rada, bodova i dr. Polaznik treba **konstantno pratiti** e-tečaj upisanog kolegija i **koristiti** njegovu funkcionalnost.

Ograničenja koja se mogu uočiti kod nastavnog osoblja predstavljaju ozbiljan problem za primjenu novijih metoda poučavanja i tehnoloških rješenja u obrazovnom području, a riječ je o sljedećem:

- **nedostatak vremena** za pripremu kvalitetnih materijala,
- **nedostatak ovlasti** za modificiranje osiguranog virtualnog prostora,
- **nedostatak znanja** za modificiranje osiguranog virtualnog prostora,
- **zanemarivanje** ideje cjeloživotnog obrazovanja i stručnog usavršavanja,
- **zanemarivanje** pozitivnih efekata i utjecaja na motivaciju korisnika e-tečaja,
- **nejasna vizija** nastavnika kod definiranja ishoda učenja za kolegij,
- **tradicionalan pristup** obrazovnim metodama prenošenja i provjeravanja znanja.

Zbog navedenih nedostataka kreirani e-tečaj često **nije konzistentan, pregledan ni intuitivan** za korištenje. U slučaju dnevnog korištenja kod polaznika izaziva **frustraciju, demotiviranost i dosadu**. E-tečajevi nisu usklađeni ni zanimljivi korisnicima te zadržavaju gotovo **isti izgled**, uz minimalne promjene, više od **10 godina**.

Računalne igre, kao drugi dio koji se navodi kao temelj za istraživanje u okviru ovog doktorskog rada, predstavljaju iznimno važnu industriju. Hamari i Parvinen (2016.) u svom istraživanju navode da **59% Amerikanaca** svaki dan odigra jednu računalnu igru. **Prosječna starost** korisnika računalnih igara je **32 godine**, a **tjedno** u prosjeku provedu **18 sati** igrajući računalne igre. Hamari i Parvinen spominju da je 2014. godine zarada od prodaje računalnih igara premašila **15 milijardi USD**. Liboriussen i Martin (2016.) navode da je kinesko tržište računalnih i mobilnih igara poraslo za 33% 2011. godine i za 35% 2012. godine te iznosi **9.5 milijardi USD**, dok je 2013. godine iznos premašio **13 milijardi USD**. Hamari i Parvinen (2016.) navode da je **uključivanje elemenata računalnih igara** u svakodnevne aktivnosti čovjeka, u što je više moguće područja, **logičan korak**. Utječe se na **motivaciju pojedinca, olakšavaju** se svakodnevne aktivnosti i čovjek postaje **produktivniji**.

7.2. PRELIMINARNE ISTRAŽIVAČKE AKTIVNOSTI

Iz razloga navedenih u poglavlju 7.1. započelo je pretraživanje stručne i znanstvene literature. Tema pretraživanja bila je **računalne igre u obrazovnom sustavu**. Rezultati istraživanja pokazali su na teme u literaturi iz područja:

- **ozbiljnih igara** (eng. *serious games*),
- **edukativnih računalnih igara** (eng. *game based learning*) i
- **elemenata računalnih igara bez prisutnosti igre** (eng. *gamification*).

S obzirom na LMS sustave koji se koriste u području e-učenja, odabrano područje istraživanja, jest korištenje **elemenata računalnih igara bez prisutnosti igre** u *online* obrazovanju, što je ujedno i predmet ove doktorske disertacije.

U **teorijskom dijelu** istraživanja, uz pregled stručne i znanstvene literature, kreiran je *anketni upitnik* za **analizu primjene gemifikacije** u e-tečajevima kao i za prikupljanje mišljenja nastavnika o trendovima u e-obrazovanju. Prikupljena su ukupno **43** korektno popunjena obrasca s odgovorima nastavnika na zadana pitanja. Nastavnici uočavaju važnost toga da **priča** i **motivacijski elementi** vidljivi u računalnim igrama mogu pozitivno utjecati na interes za nastavnu temu, no skoro polovica ispitanika (49%) nije upoznata s **teorijom tijeka**, koja je temelj zabave u igrama.

Elementi koji se koriste u Moodle sustavima identificirani su manjim dijelom u anketnim upitnicima koje su ispunjavali nastavnici, te ostalim dijelom tijekom istraživanja literature. Broj **aktivnosti** i **resursa** sveden je na **minimum** kako bi se, što je više moguće, administratorima olakšalo **održavanje**, a nastavnicima **upravljanje** aktivnostima e-tečaja.

Sustav je stabilan u pogledu pouzdanosti rada te se više od toga u praksi nije tražilo, no studenti koji su polaznici nastavnih aktivnosti spadaju u tzv. "**Generaciju Z**" te oni opisani obrazovni sustav smatraju zastarjelim, što on i jest. "**Generacija Z**" opisana prema **Ramar** i suradnici (2016.) i **Owens** (2016.), je **tehnološki napredna** generacija kod koje pojam statičnosti izaziva **nepoželjno stanje, frustraciju** i nepoželjnu **emociju**.

Aktivnosti uoči provođenja *predistraživanja* odnosile su se na kreiranje konceptualnog modela koji bi služio kao temelj za eksperiment. Model je dobio naziv eRIOOS s obzirom na primjenu **elemenata računalnih igara** u *online* **obrazovnom sustavu**. Paralelno s kreiranjem konceptualnog modela izrađuju se mjerni instrumenti i to *predtest, posttest* i *anketni upitnik* **motivacije** i **zadovoljstva**.

Izrada i testiranje *gemificiranog* Moodle e-tečaja, koji broji ukupno **24 elementa iz računalnih igara**, predstavlja posljednji korak u teorijskom istraživačkom radu. Navedeni dodaci nalaze se u **tablici 24**. Analizirani su ciljevi i nastavljeno je provođenje empirijskog dijela istraživanja prema planovima izvođenja kolegija.

Empirijski dio sastoji se od **triju odvojenih istraživanja: predistraživanje** na Sveučilištu Sjever, na odjelu Multimedije oblikovanja i primjene, te *prvo* i **drugo glavno istraživanje** na Fakultetu organizacije i informatike u Varaždinu. Ukupan broj polaznika bio je **309**, a **283 polaznika** uspješno je završilo **sve nastavne i istraživačke aktivnosti**. Zaključci istraživanja izneseni su u nastavku ove doktorske disertacije.

Mišljenje ispitanika u svim trima istraživanjima prikupljena su putem *anketnog upitnika* koji se sastoji od tri dijela. Prvi dio broji 19 čestica koje se odnose na **deskriptivne pokazatelje** grupe ispitanika, drugi dio broji ukupno 150 čestica koje se odnose na **zadovoljstvo, motivaciju, interakciju i proces učenja**, a treći dio sadrži 41 česticu koja se odnosi zainteresiranost i općenitu procjenu **mišljenja i utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika. Čestice *anketnog upitnika* su korigirane u svakoj fazi istraživanja prema **unutarnjoj konzistentnosti skala**. Uz analizu rezultata *anketnog upitnika*, analizira se i **izvještaj aktivnosti**, koji je generiran temeljem **Moodle sustava**. Izvještaj se temelji na **log zapisu** koji je povezan s pristupanjem nastavnom i nenastavnom sadržaju te bonus materijalima dostupnim unutar e-tečaja.

Razina stečenog znanja studenata mjerena je nakon dva tjedna korištenja *gemificiranog* e-tečaja. **Preduvjet** koji je zadovoljen u svim trima istraživanjima odnosi se na **nepostojanje statističke značajnosti razlike** između *kontrolne* i *eksperimentalne* skupine ispitanika. Rezultati mjerenja navedeni su u nastavku teksta.

- U **predistraživanju** prosječan broj bodova *eksperimentalne* grupe u odnosu na *kontrolnu* grupu bio je veći za **36,55%**.
- U **prvom glavnom istraživanju** prosječan broj bodova *eksperimentalne* grupe u odnosu na *kontrolnu* grupu bio je veći za **15,46%**.
- U **drugom glavnom istraživanju** prosječan broj bodova *eksperimentalne* grupe u odnosu na *kontrolnu* grupu bio je veći za **33,23%**.

7.3. KRATAK OSVRT I ZAVRŠNA RAZMIŠLJANJA

Na ovom mjestu izložen je osvrt na odabrane doktorske radove drugih istraživača, čiji se sažetak navodi u nastavku poglavlja.

Fitz-Walter (2015.) u svojoj doktorskoj disertaciji ističe rezultat istraživanja nad 46 studenata, u kojem sugerira kako su studenti koji su koristili **gemificiranu verziju** sustava **aktivniji**. Evidentiran je veći broj međusobnih **razmjena informacija** te **pozitivan efekt** vezan uz zabavu i motivaciju. **Promjene u ponašanju nisu značajne**, ali evidentirano je da su sudionici *gemificiranog* sustava primijenili **više različitih vještina** u rješavanju zadatka. Rezultati istraživanja mogu upućivati na valjanost zaključaka, ali bi se trebali uzeti sa zadržkom zbog broja ispitanika (*eksperimentalna* grupa broji 26 ispitanika, a *kontrolna* 20).

Fitz-Walter navodi kako se pretpostavljalo da će se pomoću sustava za postignuća značajno utjecati na **korisničko iskustvo, motivaciju i promjene u ponašanju**. Rezultat pokazuje pozitivne rezultate iako **ne postoje statistički značajne razlike**. Uočene su promjene u ponašanju te pokušaj varanja tijekom provođenja istraživanja.

Hamari (2015.) u svojoj disertaciji koristi bazu podataka sveučilišta Aalto unutar koje su se tijekom eksperimenta nalazila 3234 zapisa (korisnički zahtjevi, komunikacija i aktivnosti). Broj **aktivnih korisnika** bio je **723**. Rad se sastoji od **dva empirijska** istraživanja koja su zajedno trajala ukupno **18 mjeseci**. Prvo istraživanje usmjereno je na **marketing i motiviranje** korisnika **mehaničkom računalnih igara**, dok se drugo istraživanje odnosi na društvene mreže i **aktivnost** među korisnicima. Gemifikacijski sustav se primarno sastojao od **bedževa** te se pratio njihov utjecaj na korisnike. Pokazuje se i vrlo mala povezanost između **sustava, povezanosti ispitanika** te **beneficija** koje ispitanici direktno osjećaju. Zaključak je da **veličina mreže** unutar koje korisnici djeluju **nema direktan utjecaj** na **beneficije** koje korisnici očekuju, niti utjecaj na **intrinzičnu motivaciju**.

Hakulinen (2015.) unutar dokorskog rada istražuje dvije ideje. Prva ideja je kako **proširiti** obrazovanje vezano uz **računalnu znanost** pomoću gemificiranih elemenata i to posebno pomoću **bedževa i dodjelu postignuća**, a druga ideja vezana je uz utjecaj na motivaciju pomoću upotrebe računalnih igara za **virtualnu stvarnost** (eng. Alternate Reality Games, ARG). Broj ispitanika u *eksperimentalnoj* grupi bio je **142**, dok je u *kontrolnoj* grupi bio **139**. Cilj je bio utvrditi može li se gemificiranim elementima utjecati na ponašanje studenata, te postoji li korelacija između postignuća i vremena provedenom u sustavu za e-učenje.

Hakulinen u provedenom istraživanju zaključuje kako **bedževi utječu** na **ponašanje** studenata, iako studentima nije bilo uvjetovano, niti su bili nagovarani na ostvarivanje nagrada. Rezultati pokazuju da su studenti koji **posjeduju bedževe češće** bili u **online obrazovnom sustavu**, imali su **više sesija** i proveli su **više vremena** u sustavu **između** pojedinih **provjera znanja**. Mišljenja studenata bila su općenito pozitivna, iako je evidentirana i određena doza kritičnosti. Zaključuje se da bi **studentski ciljevi** trebali biti uključeni u fazu **planiranja** i trebali bi biti osnovni dio **dizajna e-tečaja**. Drugi dio istraživanja proveden je pomoću upotrebe računalnih igara za **virtualnu stvarnost (ARG)**, gdje je uočeno da sustav utječe na **intrinzičnu motivaciju** korisnika i potencijalno se može koristiti kao proširenje obrazovnog sustava.

Behnke (2015.) u doktorskoj disertaciji istražuje utjecaj korištenja elemenata računalnih igara, bez prisutnosti igre, na **studentsku motivaciju** i **ishode učenja**. U istraživanju sudjeluje **80 ispitanika**. Istraživanje uključuje *motivacijske upitnike, pretest, posttest* i analizu web sustava. Na temelju rezultata *pretest* i *posttest* provjera znanja, istraživanje pokazuje kako između *eksperimentalne* i *kontrolne* grupe ne postoji statistički značajna razlika te se tvrdnja da gemifikacija utječe na studentsku motivaciju i ishode učenja, odbacuje ($p = 0.0722$). Behnke sugerira kako bi se rezultati istraživanja trebali potvrditi ponovljenim istraživanjem u kojemu bi sudjelovalo više ispitanika.

Browne (2016.) istražuje u okviru dokorskog rada može li se pomoću gemifikacije kreirati **obrazovna mobilna aplikacija** koja će biti efikasnija od tradicionalnog poučavanja nastavnih materijala s obzirom na **ishode učenja**. U istraživanju je sudjelovalo 36 ispitanika. Ispitanici su nastavni materijal učili isključivo pomoću mobilnih uređaja **iPad**. Rezultati istraživanja pokazuju da je u **4** od **ukupno 6** aplikacija postignuta **statistički značajna razlika** između ispitanika *eksperimentalne* i *kontrolne* grupe. *Kontrolna* grupa mogla je koristiti tradicionalne metode poučavanja. *Anketni upitnik* korisničkog iskustva, provjera znanja u *posttestu* i diskusija sa studentima upućuje na **uspješnost gemificiranog dizajna**. Zaključci istraživanja su valjani, no trebalo bi organizirati ponovljeno testiranje s obzirom na broj ispitanika.

8. ZAKLJUČAK

U ovoj disertaciji prvo se daje **pregled istraživanja** iz područja primjene gemifikacije u e-učenju. Provedena je anketa među nastavnicima koji koriste e-učenje u radu sa studentima, nakon koje slijedi *predistraživanje*, te *prvo* i *drugo glavno istraživanje*. Istraživanje spada u područje društvenih znanosti, gdje se provjerava spoznaja je li primjena motivirajućih elemenata računalnih igara omogućila ostvarenje boljih rezultata po pitanju studentovog znanja. Također, analizirana je motivacija kao aktivnost studenata koji su koristili *gemificirani* e-tečaj.

Prilikom razmatranja mogućnosti okruženja unutar kojeg se provodi istraživanje potrebno je uzeti u obzir tehnološku infrastrukturu koja je sačinjena od sklopovskog i programskog dijela. Za potrebe istraživanja osigurana su dva odvojena poslužitelja (eng. *server*) na kojima se nalaze odvojeni Moodle sustavi. Poslužitelji su osigurani na **Sveučilištu Sjever** gdje su se nalazili svi *gemificirani* e-tečajevi te *klasičan* e-tečaj namijenjen *predistraživanju* i na **Fakultetu organizacije i informatike** gdje su se nalazili *klasični* e-tečajevi namijenjeni *prvom* i *drugom glavnom istraživanju*. Na Sveučilištu Sjever postavljen je Moodle 2.7 sustav za e-učenje. Sudionici sustava mogu biti nastavnici, studenti/učenici, administratori sadržaja, dizajneri multimedijских elemenata i nastavnih materijala, koji trebaju na pravilan način sudjelovati u sustavu kako bi se osigurao optimalan učinak i stanje tijekom koje je opisano u poglavlju 3.4.

Ova disertacija sastoji se od osam poglavlja čiji je kratak sadržaj opisan u nastavku rada.

- **Poglavlje "1. Uvod"** - opisuje se i definira istraživački problem te koja je tema ove disertacije. Navode se ciljevi i hipoteze istraživanja, prikazuje se slika tijekom istraživanja te opis teorijskog i empirijskog dijela istraživanja.
- **Poglavlje "2. Pedagoški i tehnološki aspekti e-učenja"** - poglavlje opisuje pojam e-učenja te njegove osnovne elemente. Opisane su sve aktivnosti i resursi prisutni u Moodle sustavu. Poglavlje završava opisom **pedagoških aspekata** koji imaju temelje u području e-učenja.
- **Poglavlje "3. Gemifikacija e-učenja"** - unutar poglavlja ističe se **teoretski** opisi i **definicije** gemifikacije kao i **osnovni elementi** koji su prisutni u gemificiranim sustavima. Opisuju se tipovi igrača te pedagoški i psihološki aspekti teorije tijekom na **uvodenje gemifikacije u obrazovni sustav**. Navode se primjeri elemenata računalnih igara u obrazovnom sustavu kao i osnovni prikaz postojećih gemifikacijskih modela.

- **Poglavlje "4. Dizajn e-tečaja"** - poglavlje navodi postojeće stanje i izgled **prosječnog Moodle** e-tečaja. Autor disertacije je razvio **konceptualan model eRIOOS**, prema kojemu je izrađen prototip *gemificiranog* sustava za korištenje u *predistraživanju* provedenom na Sveučilištu Sjever. S obzirom na prototip, pokrenuta je izrada i implementacija idejnog rješenja za *prvo glavno istraživanje*, provedeno na Fakultetu organizacije i informatike, na preddiplomskom studiju u zimskom semestru akademske godine 2015./2016. Idejno rješenje napravljeno je i za *drugo glavno istraživanje*, koje je provedeno na Fakultetu organizacije i informatike, na prvoj godini diplomskog studija u zimskom semestru akademske godine 2015./2016.
- **Poglavlje "5. Opis i obilježja istraživanja"** - poglavlje prikazuje teorijska razmatranja te se navode **ciljevi** i **hipoteze** istraživačkog rada. Ističe se **vremensko trajanje** istraživanja kao i **faze empirijskog tijeka** istraživanja. Slijedi objašnjenje **ishoda učenja** za sva tri istraživanja, zajedno s ispitnim pitanjima koji ishode i provjeravaju. Opisuju se **instrumenti** istraživačkog rada, **ispitanici** te **sadržaj svih e-tečajeva** koji se koriste u istraživanju. Poglavlje završava objašnjenjem koraka u pripremi provođenja istraživanja.
- **Poglavlje "6. Rezultati istraživanja"** - unutar poglavlja 6. daje se iscrpan pregled i analiza svih triju istraživanja. Sva tri istraživanja imaju **istu strukturu**, analiziraju se rezultati *predtesta* i *posttesta*, provjerava se statistička razlika između parova ispitanika pomoću izračunavanja **statističke značajnosti razlike** metodom t-testa između prosječnih rezultata odgovora. Provodi se **analiza unutarnjih konzistentnosti** skala u svim trima provedenim istraživanjima te se navode **zaključci** imajući u vidu hipoteze, podhipoteze i prosječne rezultate polaznika *eksperimentalnih* i *kontrolnih* e-tečaja.
- **Poglavlje "7. Diskusija"** - poglavlje ističe osvrt na preduvjete i rezultate istraživačkog rada ove disertacije. Navode se zaključci za sva provedena istraživanja i objašnjenje za prihvaćanje tvrdnji hipoteza **H1** i **H2**, isto kao i podhipoteza **H1.1**, **H2.1**, **H2.2**, **H2.3**, **H2.4** i **H2.5**. Poglavlje se zaključuje navodom nekoliko doktorskih disertacija drugih istraživača.
- **Poglavlje "8. Zaključak"** - zadnje poglavlje uz sumirani prikaz govori o metodologiji i ishodu empirijskog istraživanja. Spominju se doprinosi i ograničenja istraživanja te se navode otvoreni problemi i smjerovi za buduća istraživanja. Disertacija završava **zaključkom**, **popisom** korištene literature te **prilozima**.

8.1. METODOLOGIJA I REZULTATI ISTRAŽIVANJA

U ovoj disertaciji prikazana je primjena mješovite metodologije istraživanja. U teoretskom dijelu istraživanja korištene su kvalitativne opće znanstvene metode poput metode opservacije, deskripcije, komparacije te metode sinteze i analize sadržaja. Navedene metode koristile su se za ostvarenje prvih triju ciljeva disertacije.

- **Prvi cilj** istraživanja jest ispitati potrebu za uvođenjem elemenata računalnih igara u e-učenje na visokim učilištima.
- **Drugi cilj** jest istražiti motivirajuće elemente računalnih igara koji bi se mogli koristiti u području *online* poučavanja sadržaja informatičkih predmeta.
- **Treći cilj** predstavlja razvoj konceptualnog modela gemifikacije za poučavanje u *online* okruženju, koji je temelj za izradu *gemificiranog* Moodle e-tečaja u području poučavanja sadržaja informatičkih predmeta.

Treći cilj govori o oblikovanju **konceptualnog modela eRIOOS**, koji je kreiran za potrebe istraživačkog rada od strane autora ove disertacije. Konceptualan je model utemeljen jer se zasniva na istraživanjima drugih znanstvenika te uvažavanju njihovih zaključaka vezanih uz korištenje elemenata računalnih igara u odgojno-obrazovnom sustavu, kao i na empirijskim istraživanjima. Konceptualni model na teoretskoj razini ima **devet dodataka** (*napredovanje, top-lista, natjecanje, skriveni zabavni dodaci, transparentnost, interakcija, priča, izazovi, povratna informacija*), proširenih na razini implementacije na **ukupno 24 elementa** koji su doprinijeli kreiranju *gemificiranog* sustava. Navedeni dodaci nalaze se u **tablici 24**. Konceptualni model eRIOOS predstavlja temelj za *gemificirani* e-tečaj, koji je korišten u **predistraživanju** u okviru Sveučilišta Sjever (N=55) i u **prvom** i **drugom glavnom istraživanju** provedenom na Fakultetu organizacije i informatike (N=254).

- **Četvrti cilj** odnosi se na provjeru spoznaje je li primjena motivirajućih elemenata računalnih igara omogućila ostvarenje viših razina ishoda učenja u *eksperimentalnoj* skupini ispitanika. Konceptualni je model usmjeren na unapređenje i primjenu **elemenata računalnih igara u online obrazovnom sustavu (eRIOOS)**.

Nakon **predistraživanja** je, na temelju zapažanja i prihvaćenih elemenata konceptualnog modela eRIOOS, kreiran *gemificirani* sustav za **prvo glavno istraživanje**. Četvrti je cilj dopunjen rezultatima analize koji su dobiveni na temelju prosječnih bodova svih ispitanika tijekom provjere u *predtestu* i *posttestu*.

Nakon *prvog glavnog istraživanja* kreiran je posljednji *gemificirani* sustav, koji se koristio u *drugom glavnom istraživanju*, u kojemu se još jednom provjerava **ispravnost konceptualnog modela eRIOOS** i ostvarenje četvrtog cilja.

Prva hipoteza ove disertacije glasila je:

H1. E-tečaj dizajniran uz primjenu elemenata računalnih igara **pozitivno utječe na zainteresiranost** polaznika tog tečaja u odnosu na tečaj istog obrazovnog sadržaja, ali bez prisutnosti elemenata računalnih igara.

Kako bi se potvrdila hipoteza H1, istražena je literatura s naglaskom na motivaciju polaznika i popratne pozitivne pojave. Naglasak je bio na suvremenim informacijsko-komunikacijskim tehnologijama koje su pronašle primjenu u visokoškolskom obrazovanju.

Tvrđnja hipoteze H1 je prihvaćena.

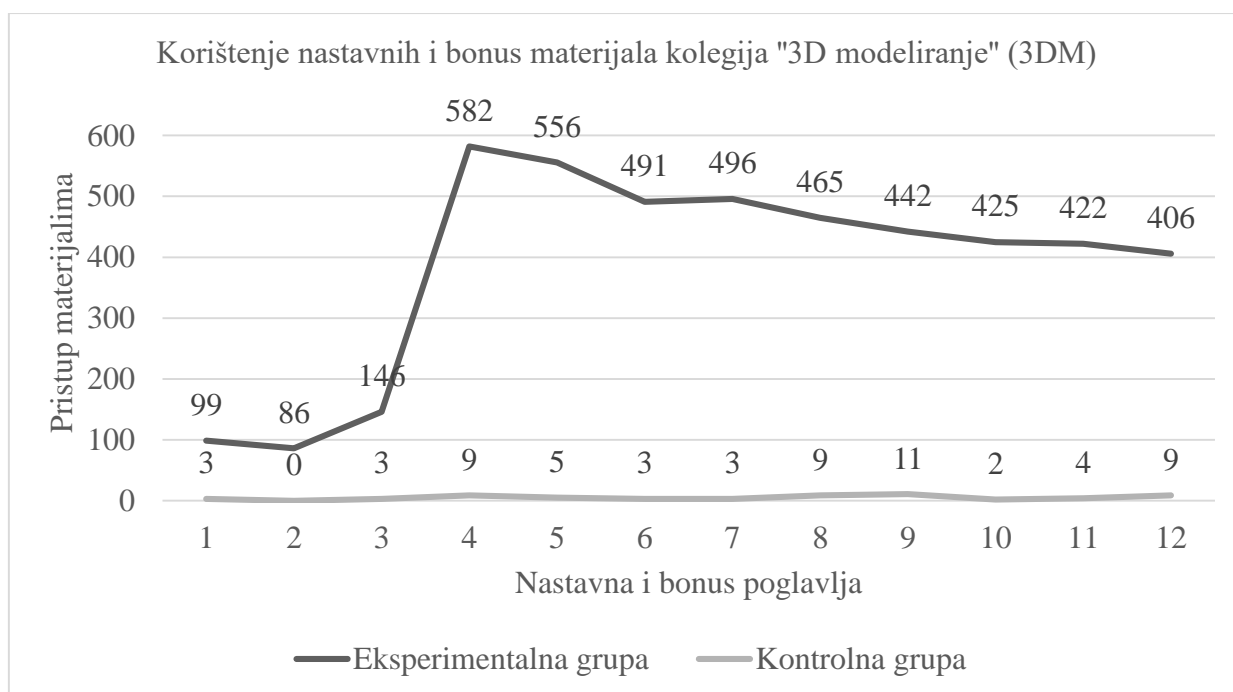
U poglavljima **6.1.4.5**, **6.2.4.5** i **6.3.4.5** prikazani su rezultati svih triju istraživanja između *eksperimentalne* i *kontrolne* grupe ispitanika. Zaključci usmjereni na tvrdnju iz **hipoteze H1** temelje se na analizi rezultata *anketnog upitnika* i na aktivnosti polaznika, tj. **objektivnim pokazateljima** koji su generirani iz svakog *gemificiranog* i *negemificiranog* e-tečaja. *Anketni upitnik* sastoji se od triju logičkih dijelova – prvi se dio odnosi na **deskriptivne pokazatelje** grupe ispitanika, drugi dio na **zadovoljstvo, motivaciju, interakciju i proces učenja**, a treći dio na zainteresiranost i općenitu procjenu **mišljenja i utjecaj motivacijskih elemenata** iz računalnih igara na učenje ispitanika. U okviru ove disertacije zainteresiranost polaznika *gemificiranog* e-tečaja mjerila se drugim dijelom anketnog upitnika koji se sastojao od 150 čestica, koje su se u svakoj fazi istraživanja korigirale prema **unutarnjoj konzistentnosti skala**. Zanimljivo je da u sva tri istraživanjima između *eksperimentalne* (**G_E**) i *kontrolne* (**G_K**) grupe **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate **treće cjeline anketnog upitnika**. Obje grupe ispitanika imaju pozitivan stav o **motivacijskim elementima** iz računalnih igara, bez obzira na *eksperimentalan* ili *kontrolni* e-tečaj.

Uz analizu rezultata *anketnog upitnika* u obzir se uzima i **izvještaj o aktivnosti** polaznika iz **Moodle e-tečaja**. U odnos se stavljaju obje grupe ispitanika (*eksperimentalna* i *kontrolna*), te se navedenim rezultatima upotpunjuje zaključak o prihvaćanju tvrdnji hipoteze H1. U svim trima slučajevima *eksperimentalna* grupa ima znatno izraženiju aktivnost u e-tečaju nad nastavnim materijalima u odnosu na *kontrolnu* grupu ispitanika.

Prva podhipoteza ove disertacije glasi:

H1.1. Elementi računalnih igara, koji su uključeni u *eksperimentalni* e-tečaj, **pozitivno utječu** na **veće korištenje nastavnih materijala, u usporedbi s klasičnim e-tečajem koji** sadrži identične nastavne materijale, bez prisutnosti elemenata računalnih igara.

Studenti kolegija "**3D modeliranje**" samostalno su se podijelili, na početku semestra, u **četiri grupe** ispitanika koje su u trenutku istraživanja korištene i kao grupe za eksperiment (dvije *kontrolne* i dvije *eksperimentalne*). U provedenom *predistraživanju* unutar kolegija "**3D modeliranje**", korišteno je ukupno 12 nastavnih i bonus materijala koje su studenti koristili minimalno 14 dana. Nastavni materijali kao i objektivni pokazatelji koji su generirani pomoću *log* zapisa iz Moodle sustava, nalaze se u tablici 65. **poglavlja 6.1.4.5** ove doktorske disertacije.

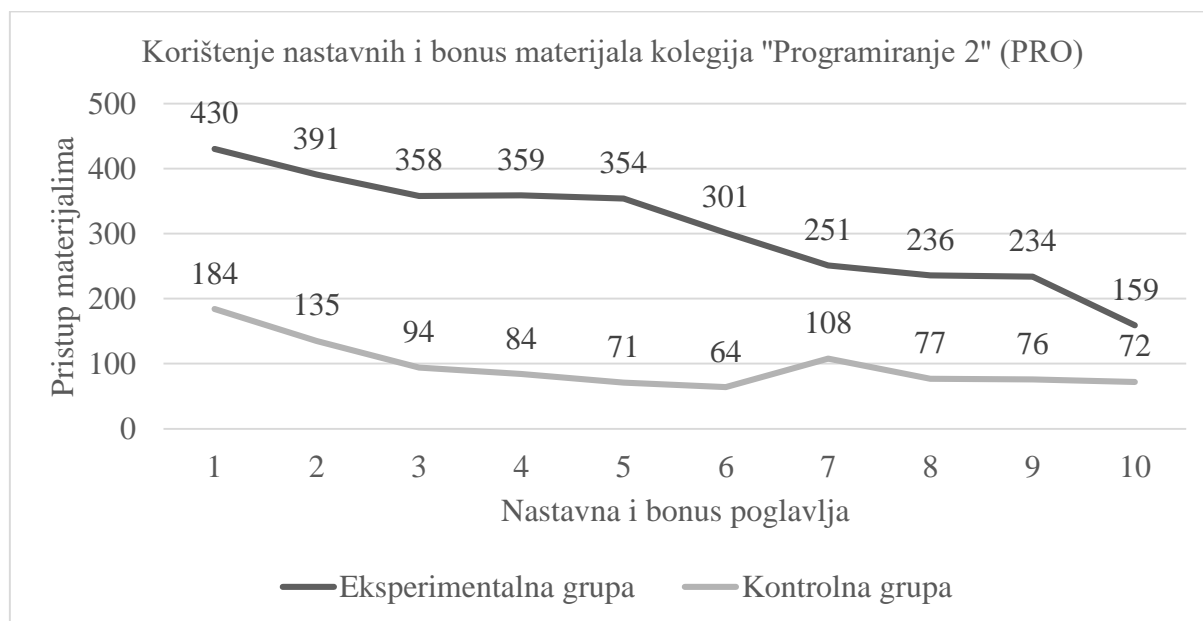


Slika 61. Ponovljeni prikaz korištenja nastavnih i bonus materijala u kolegiju "3DM"

Slika 61. originalno je prikazana u **poglavlja 6.1.4.5.**, te se navodi još jednom zbog lakšeg uvida u odnos korištenja nastavnih i bonus materijala unutar kolegija "**3D modeliranje**". Slika 61. prikazuje gotovo konstantnu nezainteresiranost za nastavne materijale kod *kontrolne* skupine ispitanika. Izgled e-tečaja bio je **vizualno neprivlačan**, te nije uključivao **niti jedan dodatni element** računalnih igara osim *avata*ra, *foruma* i *nelinearnog pristupa materijalima*.

Studentska aktivnost u *eksperimentalnom* e-tečaju nad uvodnim poglavljima bilježi slabiju aktivnost koja se može objasniti **predznanjem** studenata, te mogućim **prijelaznim razdobljem** s obzirom na to kako studenti, u okviru kolegija "3D modeliranje", do trenutka provođenja ovog istraživanja nisu koristili e-tečaj kao primarni izvor nastavnih materijala. Nakon upoznavanja s korištenjem i mogućnostima sustava, studentska aktivnost **gotovo je pet puta veća** u odnosu na uvodna poglavlja, te je **65 puta** veća u odnosu na kontrolnu skupinu ispitanika što je vidljivo u grafičkom prikazu slike 61. *Gemificirani* e-tečaj **vizualno je privlačan**, te sadrži elemente računalnih igara koji su prikazani unutar tablice 26.

Studenti u okviru kolegija "**Programiranje 2**", za razliku od studenata koji su bili uključeni u *predistraživanje* ovog doktorskog rada na kolegiju "3D modeliranje", ranije su koristili e-tečaj za potrebe informiranja i pristupanja nastavnim materijalima. U **poglavlju 5.5.** objašnjeno je kako su studenti jedne grupe na vježbama ujedno i jedna grupa u istraživanju, što znači kako je unutar kolegija "Programiranje 2" postojalo ukupno **14 grupa**, od kojih je sedam bilo *kontrolnih* i sedam *eksperimentalnih*. U provedenom *prvom glavnom istraživanju* unutar kolegija "Programiranje 2", korišteno je ukupno 10 nastavnih i bonus materijala koje su studenti koristili minimalno 14 dana. Nastavni materijali kao i objektivni pokazatelji koji su generirani pomoću *log* zapisa iz Moodle e-tečaja, nalaze se u tablicama 111. i 112. **poglavlja 6.2.4.5** ove doktorske disertacije.



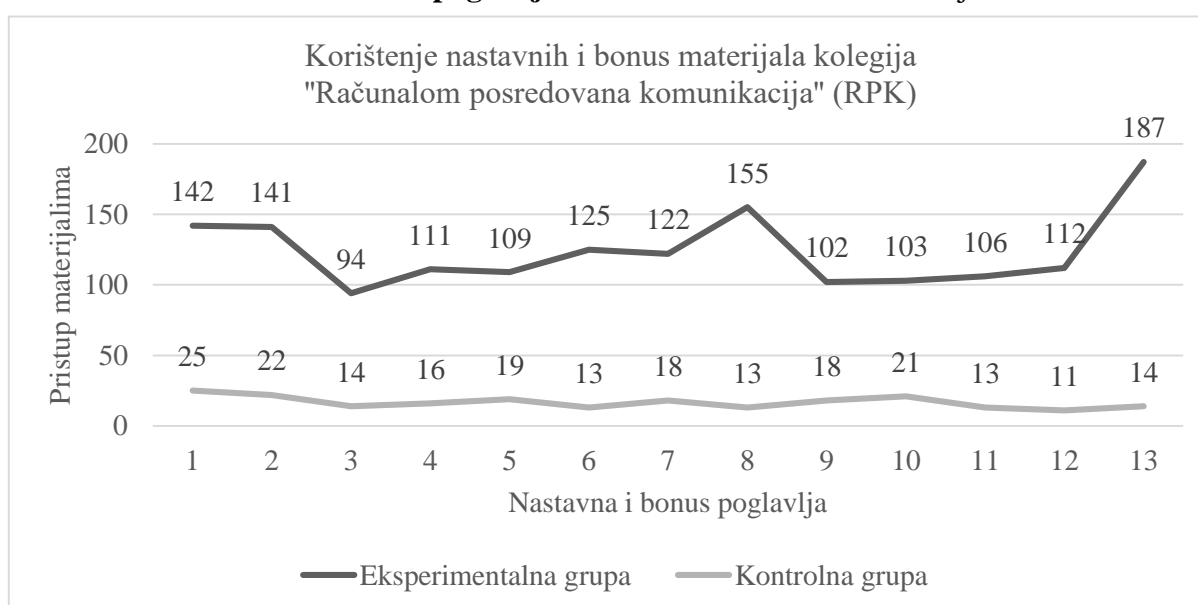
Slika 62. Ponovljeni prikaz korištenja nastavnih i bonus materijala u kolegiju "PRO"

Slika 62. originalno je prikazana u **poglavlja 6.2.4.5.**, te se navodi još jednom zbog lakšeg uvida u odnos korištenja nastavnih i bonus materijala unutar kolegija "**Programiranje 2**".

Kontrolni e-tečaj u sebi nije imao ništa osim mogućnosti korištenja *avatara, foruma, te nelinearnog pristupa* navedenim nastavnim materijalima. Slika 62. prikazuju, blago opadanje interesa za nastavnim materijalima do treće teme, nakon koje je interes kod *kontrolne* skupine ispitanika za nastavnim materijalima gotovo konstantan. U provedenom *predistraživanju*, *kontrolni* e-tečaj **prvog glavnog istraživanja** nije uključivao **ni jedan dodatni element** računalnih igara osim *avatara, foruma i nelinearnog pristupa* sadržajima.

Studentska aktivnost, u *eksperimentalnom* e-tečaju, nad uvodnim poglavljima bilježi najveću razlika između *kontrolne* i *eksperimentalne* skupine ispitanika koja je uočena na kraju prve cjeline unutar poglavlja pod nazivom: "*Uzastopno brisanje korijena hrpe (Heapsort)*". Razlika u aktivnosti je gotovo **5 puta** veća u korist *eksperimentalne* skupine ispitanika. Interes za nastavnim materijalima veći je kod *eksperimentalne* grupe ispitanika, te je zaključak isti kao i u provedenom *predistraživanju* ovog doktorskog rada.

Studenti u okviru kolegija "**Računalom posredovana komunikacija**", za razliku od studenata koji su bili uključeni u *predistraživanje* ovog doktorskog rada na kolegiju "3D modeliranje", ranije su koristili e-tečaj za potrebe informiranja i pristupanja nastavnim materijalima. Unutar kolegija "**Računalom posredovana komunikacija**" postojale su ukupno **dvije grupe**, od kojih je jedna bila *kontrolna* i jedna *eksperimentalna*. U provedenom **drugom glavnom istraživanju** unutar kolegija "**Računalom posredovana komunikacija**", korišteno je ukupno 13 nastavnih i bonus materijala koje su studenti koristili minimalno 14 dana. Nastavni materijali kao i objektivni pokazatelji koji su generirani pomoću *log* zapisa iz Moodle sustava, nalaze se u tablicama 143 i 144. **poglavlja 6.3.4.5** ove doktorske disertacije.



Slika 63. Ponovljeni prikaz korištenja nastavnih i bonus materijala unutar kolegija "RPK"

Kontrolni e-tečaj osmišljen je kao i ranija dva istraživanja te sadrži mogućnosti korištenja *avataara, foruma*, te mogućnost *nelinearnog pristupanja* nastavnim materijalima. Slika 63. prikazuju, konstantan i nizak interes za nastavnim materijalima. Izgled e-tečaja koji je vizualno sličan kontrolnom e-tečaju iz ovog istraživanja prikazan je na **slici 26**. U provedenom *predistraživanju*, *kontrolni* e-tečaj *drugog glavnog istraživanja* nije uključivao **niti jedan dodatni element** računalnih igara osim avataara, foruma i nelinearnog pristupa sadržajima.

Eksperimentalni e-tečaj sadrži **elemente računalnih igara** koji su prikazani unutar tablice 26. (poglavlje 4.3.), te su služili kao potpora nastavnim materijalima koji se navode u tablici 144. Studentska aktivnost *eksperimentalne* grupe ispitanika može se objasniti **visokim stupnjem interesa** za nastavnim materijalima, kao i **visokim stupnjem interesa** za drugačijem pristupu obrazovnim sadržajima. Najveća razlika između *kontrolne* i *eksperimentalne* skupine ispitanika uočena je na kraju druge cjeline unutar poglavlja pod nazivom: "*Primjena animacije na Webu*". Razlika u aktivnosti je **13 puta** veća u korist *eksperimentalne* skupine ispitanika. Interes za nastavnim materijalima veći je kod *eksperimentalne* grupe ispitanika, te je zaključak isti kao i u provedenom *predistraživanju*, te *prvom glavnom istraživanju* ovog doktorskog rada.

S obzirom na objektivne rezultate generirane temeljem *log* zapisa o aktivnostima nad nastavnim i bonus materijalima iz Moodle sustava koji je korišten u *drugom glavnom istraživanju*, kao i u slučaju provedenog *predistraživanja* i *prvog glavnog istraživanja*, može se zaključiti kako elementi računalnih igara koji su uključeni u *eksperimentalni* e-tečaj **utječu na veće korištenje nastavnih materijala** čime se **prihvća tvrdnja podhipoteza H1.1** ove doktorske disertacije.

Druga hipoteza ove disertacije glasila je:

H2. E-tečaj dizajniran uz primjenu elemenata računalnih igara omogućuje **postizanje boljih rezultata** polaznika u odnosu na tradicionalne pristupe e-učenju, imajući u vidu razinu **stečenog znanja** iz određenog nastavnog sadržaja.

Sva tri istraživanja provedena su na isti način.

- **Prvi korak** bio je upoznavanje ispitanika s načinom provođenja i svrhom istraživanja. Ispitanici su u eksperimentu bili ista grupa kao i na laboratorijskim vježbama. U prvom koraku nije bilo poznato je li grupa ispitanika *kontrolna* ili *eksperimentalna*.
- **Drugi korak** bio je provjeriti jesu li grupe podjednake u predznanju. Kod ispitanika se *predtestom* provjeravalo predznanje iz područja poučavanog unutar određenog kolegija. Svako od triju istraživanja odnosi se na drugo nastavno područje. Na temelju ostvarenih bodova utvrđeno je da **ne postoji statistički značajna razlika** s obzirom na prosječne rezultate *predtesta* te se donosi zaključak o zadovoljavanju početnih uvjeta istraživanja. S obzirom na prosječne bodove, grupe se odvajaju u *eksperimentalnu* i *kontrolnu*. Objе grupe ispitanika, upućene su u njima namijenjene e-tečaje, gdje su izvršavale određene nastavne aktivnosti.
- **Treći korak** odnosi se na aktivnosti polaznika e-tečaja koji nove nastavne materijale proučavaju isključivo u e-tečaju i to minimalno 14 dana. U tjednu koji slijedi provedeno je testiranje stečenog znanja primjenom *posttest* instrumenta Testiranje **statističke značajnosti razlike** metodom t-testa provodilo se između istih skupina ispitanika kao i u drugom koraku. Na temelju rezultata *posttesta* donosi se zaključak o **postojanju statistički značajne razlika između** rezultata *posttesta* *eksperimentalne* i *kontrolne* grupe ispitanika uz mogućnost pogreške od 1% ili 5%. Ovisno o rezultatima trećeg koraka, donosi se odluka o prihvatanju tvrdnje hipoteze H2.

Tvrdnja hipoteze H2 je prihvaćena.

U poglavljima **6.1.4.5**, **6.2.4.5** i **6.3.4.5** prikazani su rezultati svih triju istraživanja koja se odnose i na tvrdnju hipoteze H2, a temelje se na istraživanju između *eksperimentalne* i *kontrolne* grupe ispitanika. Zaključci usmjereni na tvrdnju iz **hipoteze H2** temelje se na prosječnim rezultatima *predtesta* i *posttesta*, tj. na **postojanju statistički značajne razlika između** rezultata *posttesta* *eksperimentalne* grupe i *kontrolne* grupe ispitanika. Sva tri istraživanja imaju zadovoljavajuće ishode i zaključke na temelju kojih se **prihvaća tvrdnja hipoteze H2**.

Druga podhipoteza ove disertacije glasi:

H2.1. *Eksperimentalna* grupa ispitanika, koja je u *predtest* provjeri znanja ostvarila **minimalno 50%** bodova, postići će **statistički značajnije** rezultate u odnosu na *kontrolnu* grupu ispitanika, koja je u *predtest* provjeri znanja ostvarila **minimalno 50%** bodova, s obzirom na ostvarene bodove u *posttest* provjeri znanja.

Iz **dodatne analize *posttesta***, prikazane unutar **poglavlja 6.1.2, 6.2.2, 6.3.2**, ove doktorske disertacije, koja je temeljena na izdvajanju studenata koji su ostvarili **minimalno 50% ukupnih bodova** u provedenom *predtestu*, u **sva tri istraživanja** mogu se uočiti nekoliko značajnih pokazatelja koji se navode u nastavku ove disertacije. U toku ovog istraživanja provelo se ukupno **30 međusobnih uspoređivanja** između *eksperimentalne* i *kontrolne* skupine ispitanika, gdje je prosječan broj bodova bio veći u korist *eksperimentalne* skupine ispitanika **ukupno 28 puta**.

U jednom slučaju prosječan broj bodova je **identičan** između dvije skupine ispitanika i samo je u **jednom slučaju** prosječan broj bodova bio **veći u kontrolnoj skupini** ispitanika.

Osim prosječnih bodova, izračunata je standardna devijacija i Studentova t-distribucija kojom se utvrdila značajnost između dobivenih rezultata *kontrolne* i *eksperimentalne* skupine. Navedena analiza podijeljena je prema skupini pitanja gdje postoji analiza **zatvorenog tipa** pitanja, analiza **otvorenog tipa** pitanja, te analiza **ukupnog rezultata**. Usporedni pokazatelji navode se u tablici 147., u nastavku ove disertacije.

Statistički značajna razlika ostvarena je u **prvom glavnom istraživanju** gdje je u *posttest* provjeri znanja sudjelovalo i najviše ispitanika (N=118) uz primjenu dodatnog uvjeta prema kojemu se u obzir uzimaju studenti koji su u *predtest* provjeri znanja ostvarili **minimalno 50% ili više** od ukupnog broja bodova. Granična statistički značajna razlika postignuta je u **predistraživanju** (N=25), dok u **drugom glavnom istraživanju** (N=44) statistički značajne razlike nije bilo u slučaju pitanja **otvorenog tipa**. Navedeni slučajevi gdje se statistički značajna razlika nije uočila, nisu utjecali na **ukupan rezultat** u kojem su analizirana **sva pitanja**. Ukupni rezultati pokazuju kako je *eksperimentalna* skupina ispitanika imala bolje rezultate uz **prisutnost statistički značajne razlike u sva tri istraživanja**.

Tvrđnja podhipoteze H2.1 je potvrđena. Odluka se temelji na analizi *posttest* provjere znanja koja je detaljno prikazana u **poglavlju 6.1.2., 6.2.2. i 6.3.2**, isto kao i u poglavljima **6.1.4.5., 6.2.4.5., te 6.3.4.5.** unutar tablice 147. ove doktorske disertacije.

Tablica 147. Usporedni prikaz analize odgovora iz provedenog *posttesta* svih triju istraživanja (za ispitanike koji su ostvarili minimalno **50% mogućih bodova u predtestu**)

<i>Predistraživanje</i>	Zatvoreni tip pitanja (uk. broj pitanja = 26)		Otvoreni tip pitanja (uk. broj pitanja = 6)		Ukupni rezultat (uk. broj pitanja = 32)	
	Eksp.	Kont.	Eksp.	Kont.	Eksp.	Kont.
Grupa ispitanika						
Prosjeck bodova	19,42	14,15	4,17	2,62	23,58	16,77
Stand. devijacija	3,80	3,16	1,75	2,02	5,42	5,04
Broj ispitanika	12	13	12	13	12	13
t vrijednost	3,77		2,04		3,26	
p vrijednost	0,001		0,052		0,003	

<i>Prvo glavno istraživanje</i>	Zatvoreni tip pitanja (uk. broj pitanja = 25)		Otvoreni tip pitanja (uk. broj pitanja = 5)		Ukupni rezultat (uk. broj pitanja = 30)	
	Eksp.	Kont.	Eksp.	Kont.	Eksp.	Kont.
Grupa ispitanika						
Prosjeck bodova	12,08	10,49	2,14	1,32	14,37	11,81
Stand. devijacija	4,99	4,39	1,59	1,17	5,88	5,07
Broj ispitanika	59	59	59	59	59	59
t vrijednost	1,84		3,17		2,53	
p vrijednost	0,068		0,002		0,012	

<i>Drugo glavno istraživanje</i>	Zatvoreni tip pitanja (uk. broj pitanja = 25)		Otvoreni tip pitanja (uk. broj pitanja = 6)		Ukupni rezultat (uk. broj pitanja = 31)	
	Eksp.	Kont.	Eksp.	Kont.	Eksp.	Kont.
Grupa ispitanika						
Prosjeck bodova	15,61	13,19	6,78	5,62	22,39	18,81
Stand. devijacija	4,35	3,34	3,03	2,69	6,06	4,06
Broj ispitanika	23	21	23	21	23	21
t vrijednost	2,05		1,34		2,28	
p vrijednost	0,046		0,187		0,027	

Iz tablice 147. vidljivo je kako su elementi računalnih igara, ugrađeni u e-tečaj *eksperimentalne* skupine ispitanika, imali pozitivno djelovao u sva tri istraživanja. Analizirala se i razina pojedinih tipova pitanja, pa je tako vidljivo kako postoji statistički značajna razlika u slučaju **zatvorenog tipa pitanja**, gdje je *eksperimentalna* grupa imala bolje rezultate u sva tri istraživanja. Isto vrijedi i **za ukupni rezultat u sva tri istraživanja**.

U slučaju **otvorenog tipa** pitanja, *eksperimentalna* skupina ispitanika imala je u sva tri slučaja veći prosječan broj bodova i to u *predistraživanju* ostvarila je **59,16%** više bodova od *kontrolne* skupine, u *prvom glavnom istraživanju* ostvarila je **62,12%** više bodova od *kontrolne* skupine, te u *drugom glavnom istraživanju* ostvarila je **20,64%** više bodova od *kontrolne* skupine ispitanika.

S obzirom na rezultate dijelova *posttesta* koji ispituju **više razine ishoda učenja**, vidljivo je kako u oba slučaja, s **ukupnim brojem ispitanika** i kod ispitanika koji su postigli **50% ili više mogućih bodova** u *predtest* provjeri znanja, **postoji statistički značajna razlika** između *eksperimentalne* i *kontrolne* skupine ispitanika.

Viša razina ishoda učenja mjerena je samo u *prvom glavnom istraživanju* zbog broja ispitanika i težine nastavnih sadržaja. Dodatni kriterij **nije utjecao** na rezultate mjerenja osim što je smanjio broj ispitanika koji su ušli u obzir za navedenu analizu (N=118). Na temelju prosječnih rezultata i statističke značajnosti kod pitanja otvorenog tipa u slučaju viših razina ishoda učenja, zaključuje se kako *gemificirani* sustav pozitivno utječe na ostvarenje **viših razina ishoda učenja** što je potvrđeno kroz *prvo glavno istraživanje* u kojemu je sudjelovao 201 ispitanik. Navedenim je **ispunjenje 4. cilja** ove disertacije ocijenjeno **pozitivnim**.

Tablica 148. Skraćeni prikaz analize odgovora iz provedenog *posttesta* svih triju istraživanja (za ispitanike koji su ostvarili minimalno **50% mogućih bodova u predtestu**)

Grupa ispitanika	Kolegij "3DM" (uk. broj pitanja = 32)		Kolegij "PRO" (uk. broj pitanja = 30)		Kolegij "RPK" (uk. broj pitanja = 31)	
	Eksp.	Kont.	Eksp.	Kont.	Eksp.	Kont.
Prosjeck bodova	23,58	16,77	14,37	11,81	22,39	18,81
Stand. devijacija	3,80	5,42	5,04	5,88	5,07	6,06
Broj ispitanika	12	13	59	59	23	21
t vrijednost	3,26		2,53		2,28	
p vrijednost	0,003		0,012		0,027	

*Eksp. = *eksperimentalna* grupa, *Kont. = *kontrolna* grupa

Unutar tablice 148. navode se prosječni rezultati (bodovi) iz sva tri provedena istraživanja u okviru ovog doktorskog rada. *Eksperimentalna* skupina ispitanika postigla je bolji uspjeh, u odnosu na *kontrolnu* skupinu ispitanika, po pitanju prosječnih bodova u *posttest* provjeri znanja u sva tri istraživanja, pri čemu je u *predistraživanju* *eksperimentalna* skupina ispitanika postigla veće bodove od *kontrolne* skupine ispitanika za **40,60%**. U *prvom glavnom istraživanju*, odnos između *eksperimentalne* i *kontrolne* skupine ispitanika iznosi **21,67%**, dok je odnos između *eksperimentalne* i *kontrolne* skupine ispitanika u *drugom glavnom istraživanju* **19,03%**.

S obzirom na rezultat prosječnih bodova *posttest* provjere znanja u okviru *predistraživanja*, *prvog glavnog istraživanja*, te *drugog glavnog istraživanja* gdje su analizirani rezultati samo onih ispitanika koji su ostvarili **minimalno 50% od ukupnih** bodova, zaključuje se kako između ispitanika *eksperimentalne* i *kontrolne* grupe ispitanika u sva tri istraživanja **postoji statistički značajna razlika** čime se i **prihvća tvrdnja podhipoteza H2.1**.

Treća i četvrta podhipoteza ove disertacije glase:

H2.2. Bez obzira na spol ispitanika, **50% najbolje** rangiranih studenata *eksperimentalne* grupe ispitanika, *prvog glavnog istraživanja*, ostvarit će statistički značajniji rezultat u odnosu na **50% najbolje** rangiranih studenata *kontrolne* grupe ispitanika.

H2.3. Bez obzira na spol ispitanika, **50% najlošije** rangiranih studenata *eksperimentalne* grupe ispitanika, *prvog glavnog istraživanja*, ostvarit će statistički značajniji rezultat u odnosu na **50% najlošije** rangiranih studenata *kontrolne* grupe ispitanika.

Kako bi se treća podhipoteza H2.2 i četvrta podhipoteza H2.3 potvrdile, u okviru *prvog glavnog istraživanja* provedena je *predtest* provjera znanja na temelju koje se dobio popis ispitanika koji su zadovoljili uvjet o ostvarivanju **minimalno 50% od ukupnog broja** bodova. Nakon provedene *posttest* provjere znanja, ispitanici *kontrolne* i *eksperimentalne* skupine se grupiraju tako da se izdvaja **50% najboljih** i **50% najlošijih** ispitanika iz obje grupe.

Rezultati analize prikazan u tablici 115. poglavlja 6.2.4.5., pokazuju kako između **50% najboljih** ispitanika **postoji statistički značajna razlika** u slučaju bodova iz *posttest* provjere znanja. Izračunata **t vrijednost** iznosi **2,578**, dok **p vrijednost** iznosi **0,011**. *Eksperimentalna* skupina ispitanika (N=60) ostvarila je u *posttest* provjeri znanja bolji rezultat od *kontrolne* skupine ispitanika (N=59) za **21,93%**.

S obzirom na rezultat bodova *posttest* provjere znanja u okviru *prvog glavnog istraživanja*, gdje je napravljena analiza **50% najboljih** ispitanika iz *eksperimentalne* grupe (N=60) s **50% najboljih** ispitanika iz *kontrolne* grupe (N=59), zaključuje se kako između navedenih skupina **postoji statistički značajna razlika** koja se temelji na t-test analizi gdje je **p vrijednost 0,011** čime se i **prihvaća tvrdnja podhipoteza H2.2** ove doktorske disertacije.

U analizi prikazanoj u tablici 115. poglavlja 6.2.4.5., vidljivo je kako između **50% najlošijih** ispitanika, **ne postoji statistički značajna razlika**, unatoč većoj prosječnoj vrijednosti bodova koja je evidentirana u *eksperimentalnoj* grupi ispitanika. *Eksperimentalna* skupina ispitanika (N=39) ostvarila je u *posttest* provjeri znanja bolji rezultat od *kontrolne* skupine ispitanika (N=43) za **12,96%**.

U slučaju podhipoteze H2.3 gdje je napravljena analiza **50% najlošijih** ispitanika iz *eksperimentalne* grupe (N=39) s **50% najlošijih** ispitanika iz *kontrolne* grupe (N=43), zaključuje se kako između navedenih skupina **ne postoji statistički značajna razlika**, čime se i **odbacuje tvrdnja podhipoteza H2.3** ove doktorske disertacije.

Peta i šesta podhipoteza ove disertacije glase:

H2.4. Bez obzira na predznanje ispitanika, studenti **muškog spola** *eksperimentalne* grupe u *prvom glavnom istraživanju* ostvarit će statistički značajniji rezultat u odnosu na studente **muškog spola** *kontrolne* grupe ispitanika.

H2.5. Bez obzira na predznanje ispitanika, studenti **ženskog spola** *eksperimentalne* grupe u *prvom glavnom istraživanju* ostvarit će statistički značajniji rezultat u odnosu na studente **ženskog spola** *kontrolne* grupe ispitanika

Kako bi se peta podhipoteza H2.4 i šesta podhipoteza H2.5 potvrdile, u okviru *prvog glavnog istraživanja* provedena je *posttest* provjera znanja na temelju koje se dobio popis ispitanika koji su zadovoljili uvjet za sudjelovanje u istraživanju, te je bilo moguće provesti t-test analizu rezultata nad ostvarenim bodovima s ciljem prihvaćanja ili odbacivanja podhipoteza H2.4 i H2.5 ove doktorske disertacije. Ukupan broj pitanja u *posttest* provjeri znanja bio je 30, dok je ukupan broj ispitanika koji su sudjelovali u *posttest* provjeri znanja bio **201**.

U poglavlju **6.2.4.5.** nalazi se prikaz rezultata gdje se uspoređuju muški ispitanici iz *eksperimentalne* grupe (N=80) s muškim ispitanicima iz *kontrolne* grupe (N=77). Iz tablice 116. vidljivo je kako između ispitanika **muškog spola postoji statistički značajna razlika** u slučaju bodova iz *posttest* provjere znanja. Izračunata **t vrijednost** iznosi **2,462**, dok **p vrijednost** iznosi **0,0149**. *Eksperimentalna* skupina ispitanika (N=80) ostvarila je u *posttest* provjeri znanja bolji rezultat od *kontrolne* skupine ispitanika (N=77) za **18,88%**, čime se i zaključuje kako između navedenih skupina ispitanika **postoji statistički značajna razlika** u korist *eksperimentalne* skupine ispitanika čime se i **prihvća tvrdnja podhipoteza H2.4** ove doktorske disertacije.

U poglavlju **6.2.4.5.** nalazi se prikaz rezultata gdje se uspoređuju ispitanici **ženskog spola** iz *eksperimentalne* grupe (N=19) s ispitanicima **ženskog spola** iz *kontrolne* grupe (N=25). U analizi između ispitanika **ženskog spola**, temeljem t-test provjere, ističe se kako **statistički značajna razlika**, između *eksperimentalne* i *kontrolne* grupe ispitanika, **ne postoji** unatoč većoj prosječnoj vrijednosti bodova za **20,26%** koja je evidentirana u *eksperimentalnoj* grupi ispitanika. Temeljem navedenog, zaključuje se, kako bez obzira na ostvareni prosječni bolji rezultat kod *eksperimentalne* skupine ispitanika, **statistički značajna razlika ne postoji**, čime se **tvrdnja podhipoteza H2.5** ove doktorske disertacije i **odbacuje**. Uzrok ovakvom rezultatu može biti u malom broju ispitanika.

8.2. OSTALI REZULTATI ISTRAŽIVANJA

Doprinos istraživanja podijeljen je na društveni, znanstveni i praktični radi lakše generalizacije rezultata.

- **Društveni doprinos** usmjeren je na sistematiziranje i kreiranje konceptualnog modela eRIOOS, koji predstavlja temelj za **implementaciju elemenata računalnih igara** u odgojno-obrazovni sustav. Model sadrži logički prikaz dviju razina složenosti. Jednostavniji prikaz sadrži **devet elemenata** (*napredovanje, top-lista, natjecanje, skriveni zabavni dodaci, transparentnost, interakcija, priča, izazovi, povratna informacija*), dok je složeniji prikaz vezan uz razinu implementacije i prikazuje ukupno **24 elementa** (vidi tablicu 24.), koji se ugrađuju u postojeće Moodle sustave minimalne verzije 2.7. Unutar poglavlja 4.2. navodi se niz elemenata koji se sugeriraju za korištenje i nužni su za kreiranje *gemificiranog* e-tečaja, tj. sustava koji uključuje motivirajuće elemente iz računalnih igara.
- **Znanstveni doprinos** vezan je uz provjeru spoznaje kako *gemificirani* sustav za e-učenje utječe na veće korištenje sadržaja tečaja mjereno **objektivnim pokazateljima** koji su prisutni u Moodle sustavu. Navedeno je prikazano unutar poglavlja **6.1.4.5, 6.2.4.5. i 6.3.4.5.**, unutar **izvještaja aktivnosti** polaznika iz **Moodle sustava**. U odnos je stavljen objektivni pokazatelj za obje grupe ispitanika (*eksperimentalna i kontrolna*), temeljen na svim provedenim istraživanjima (*predistraživanje, prvo glavno istraživanje i drugo glavno istraživanje*), a rezultatima se upotpunjuje zaključak o prihvaćanju tvrdnji **hipoteze H1** i **podhipoteze H1.1**. Analizom anketnih upitnika prikazuje se kako elementi računalnih igara utječu na **zainteresiranost** studenata za nastavnim materijalima. Obje skupine ispitanika pokazuju pozitivan stav i želju za primjenom elemenata računalnih igara unutar obrazovnog sustava, što je vidljivo iz analize **treće cjeline anketnog upitnika** koji se sastoji od ukupno 41 čestice. Rezultat je konzistentan unutar svih triju provedenih istraživanja.

Nadalje, doprinos je vezan i uz odnos **korištenih elemente računalnih igara i ishoda učenja** polaznika *gemificiranog* e-tečaja. Ni jedan rad do trenutka provođenja istraživačkih aktivnosti u okviru ove disertacije nije imao detaljno opisan sustav Moodle dodataka koji bi se mogli koristiti u svrhu gemificiranja e-tečaja. *Prvo* i *drugo glavno istraživanje* obuhvaćaju ukupno 24 elementa računalnih igara koji su implementirani unutar *gemificiranog* Moodle e-tečaja, čime su obuhvaćeni gotovo svi elementi koji bi se mogli koristiti unutar odgojno-obrazovnog sustava. Implementirani elementi nalaze se u tablici 24.

- **Praktičan doprinos** doktorske disertacije temeljen je na **kreiranju i testiranju gemificiranog e-tečaja** u Moodle okruženju u području poučavanja sadržaja informatičkih predmeta. Kreirana su **tri odvojena Moodle e-tečaja**, koja obuhvaćaju tri odvojena nastavna područja informatike (3D računalnu grafiku, programiranje i multimediju). Sustavi su testirani i njihov utjecaj na polaznike mjereno je analizom prosječnih **rezultata provjere znanja** u *posttestu*. S obzirom na početne uvjete koje su svi ispitanici zadovoljili, utvrđene su **statistički značajne razlike** uz mogućnost pogreške od 1% ili 5% između *kontrolne* i *eksperimentalne* grupe ispitanika unutar svih triju istraživanja, što utječe i na **prihvatanje tvrdnje hipoteze H2**, isto kao i tvrdnje **podhipoteza H2.1, H2.2 i H2.4**. Tvrdnje **podhipoteza H2.3 i H2.5 su odbačene**.

Očekivani rezultat prije istraživanja bila je **veća motivacija i bolji ishodi** učenja kod studenata koji su koristili *gemificirani* sustav, što je i objašnjeno u **poglavlju 8.1** ovog rada.

Empirijsko istraživanje predstavlja **temelj** za **teorijska razmatranja** po pitanju korištenja elemenata računalnih igara u **e-učenju** i u **obrazovnom sustavu u cijelosti**. Disertacija se temelji na **teorijskom i empirijskom istraživanju** te se navedeni zaključci mogu koristiti u **budućim istraživanjima** i **dopunjavati** novim spoznajama o **motiviranju korisnika** te utjecaju na **ishode učenja** kod studenata. Autor ove doktorske disertacije **zaključuje** kako je osigurao dovoljno informacija i činjenica za donošenje pravovaljanih zaključaka s obzirom na sljedeće aktivnosti:

1. **pregled** relevantne stručne i znanstvene **literature**,
2. kreirani **konceptualni eRIOOS** model,
3. kreirana **tri mjerna instrumenta** (*predtest, posttest* i *anketni upitnik*),
4. kreiran *pilot eksperimentalan e-tečaj* s ukupno **17 gemificirana dodatka**,
5. *kreirana dva glavna eksperimentalna e-tečaja* s ukupno **24 gemificirana dodatka**,
6. **provedena tri uzastopna istraživanja** na ukupno **309 (283)** ispitanika,
7. analizirane **dvije glavne hipoteze**,
8. analiziranih **šest podhipoteza**.

8.3. OGRANIČENJA ISTRAŽIVANJA

Istraživanje provedeno u okviru disertacije posjeduje navedena ograničenja.

- **Elementi računalnih igara koji nisu uključeni u konceptualni model eRIOOS**

U model su implementirana **24 elementa računalnih igara** navedena u **tablici 24**. Razvojem informacijsko-komunikacijske tehnologije način na koji korisnici mogu biti uključeni u sustav često doživljava promjene. Inovativna programska rješenja koja se pojavljuju na globalnom tržištu i kreativne računalne igre utječu na način na koji korisnik percipira zabavu. Mijenjaju se trendovi vezani uz pojam zabave, pa samim time i obrasci ponašanja. *Gemificirani* sustav je u trenutku provođenja istraživanja uključivao **većinu elemenata računalnih igara** koja su bila dostupna unutar Moodle platforme. S obzirom na to kako je **količina uključenih dodataka** brojčano nadišla istraživačke koncepte drugih istraživača i da su uključeni dodaci **kompatibilni** za rad s e-tečajem, konceptualan **model eRIOOS prihvaćen je** kao temelj za implementaciju *gemificiranog* e-tečaja u ovom istraživanju.

- **Broj ispitanika koji su sudjelovali u istraživanju**

Ispitanici koji su sudjelovali u istraživanju bili su studenti Sveučilišta Sjever i studenti Fakulteta organizacije i informatike. Prilikom planiranja istraživačkih aktivnosti nije postojao način na koji bi se mogao znati točan broj budućih ispitanika zato što su upisi studenata u više godine bili u tijeku, kao i upisi kolegija koji će studenti pohađati.

Kolegij "**3D modeliranje**" Sveučilišta Sjever bio je ujedno i izborni kolegij, za razliku od kolegija "**Programiranje 2**" i "**Računalom posredovana komunikacija**" Fakulteta organizacije i informatike. Pretpostavio se očekivani broj ispitanika, gdje je bila riječi o 50 ispitanika za kolegije "3D modeliranje" i "Računalom posredovana komunikacija". Za kolegij "Programiranje 2" očekivano je 200 studenata. Jedan dio studenata očekivano je otpao zbog razloga koji autoru disertacije nisu poznati. Broj ispitanika koji su pristali na istraživačke aktivnosti i uredno izvršili svoje obaveze ne odstupa od planiranog okvirnog broja ispitanika. U kolegiju "**3D modeliranje**" **bio je 55 ispitanika**, u "**Programiranju 2**" **bio je 201 ispitanik**, dok su u kolegiju "**Računalom posredovana komunikacija**" **bila 53 ispitanika**. Unutar "3D modeliranja" nije otpao ni jedan ispitanik, unutar "Programiranja 2" otpalo je 9 ispitanika u razdoblju između *predtesta* i *posttesta*, a prilikom provođenja *anketnog upitnika* još 10 ispitanika. Unutar kolegija "Računalom posredovana komunikacija" otpala su 2 ispitanika. Ukupan broj ispitanika je **283** te se na temelju tog broja mogu donijeti valjani zaključci o ciljevima istraživanja i tezama postavljenih hipoteza.

- **Opterećenje studenata drugim obavezama**

Istraživanje je provedeno tijekom izvođenja redovne nastave na objema institucijama. Studenti su uz obveze vezane za ostale kolegije imali i obvezu koristiti *gemificirani* i *negemificirani* sustav. Važno je naglasiti da je sudjelovanje bilo dobrovoljno. Provođenje eksperimenta planirano je u vrijeme kada studenti nisu imali ni jedan kolokvij ni završni ispit. Individualni zadaci i obveze na studiju nisu mogli biti uključeni u analizu studentskog opterećenja, gdje je moguće da su studenti u vrijeme korištenja *gemificiranog* sustava imali i ostale obveze vezane uz druge kolegije. Rezultati istraživanja u kojima su studenti sudjelovali pokazuju statističku značajnu razliku između *eksperimentalne* i *kontrolne* grupe, čime se ne dovodi u pitanje preopterećenje studenata te se ranije opisani zaključci mogu proglasiti valjanima.

- **Vremenski period korištenje *eksperimentalnog* sustava**

Istraživačke aktivnosti za svaki kolegij posebno su planirane s obzirom na nastavni plan i program kolegija te ostala opterećenja studenata. Odlučeno je da se mjerenje treba provesti **tijekom 2 do 4 tjedna** od trenutka kada studenti pristupe *eksperimentalnom* sustavu. Važno za naglasiti jesti to kako su uz korištenje ***eksperimentalnog* sustava**, studenti trebali proći **tri odvojena testiranja**.

Testiranje je bilo vezano uz **provjeru predtestom**, nakon koje su slijedila 2 do 4 tjedna korištenja ***eksperimentalnog* sustava**, a nakon toga *posttest* i *anketni upitnik*.

S obzirom na to kako studenti proučavaju nastavnu tematiku **samostalno**, bez prisutnosti i stručnog vođenja nastavnika putem e-učenja, trebalo je imati na umu da nastavna cjelina ne bude prevelika. Isto tako studentske aktivnosti koje su pratile nastavnu cjelinu trebale su biti usklađene i prilagođene godini studija.

Posljednja prepreka odnosila se na mogućnost **preklapanja s obvezama** drugih kolegija u slučaju ako bi provedba eksperimenta trajalo 3 ili 4 tjedana, čime bi rezultati istraživanja mogli postati diskutabilni. Iz navedenih razloga odlučeno je da će korištenje *eksperimentalnog* sustava biti osigurano kroz minimalno 14 dana. Alternativa je moguća jedino u vremenskom razdoblju kada sve nastavne obveze miruju, tj. tijekom praznika. Druga mogućnost je koristiti drugi profil sudionika, kada se u obzir ne bi uzimali studenti bilo koje godine studija.

8.4. SMJERNICE ZA BUDUĆA ISTRAŽIVANJA

Uočena ograničenja upućuju na mogućnosti u promjenama i dopunama istraživanja. Sustavi koji svoju primjenu temelje na elementima računalnih igara radi motiviranja korisnika trebaju svakih pola godine analizirati trendove na tržištu i uočavati poveznice u interakciji s obrazovnim sustavima.

Uvođenje elemenata računalnih igara u odgojno-obrazovne sustave traži iznimno planiranje aktivnosti. U literaturi autori Goasduff i Pettey (2011.) te Kumar i Herger (2013.) navode kako će u budućnosti većina gemifikacijskih sustava biti neuspješna **zbog lošeg dizajna**. S navedenim slaže se i autor ove disertacije. Prilikom kreiranja *gemificiranih* sustava potrebno je uključiti nekoliko eksperata koji trebaju surađivati na implementaciji sustava. Prvi ekspert treba biti iz **područja** koje je obuhvaćeno **nastavnom cjelinom**. Drugi ekspert treba biti iz **područja računalnih igara**. Treći ekspert treba biti iz **područja programiranja**, gdje se odabir treba prilagoditi platformi koja služi za praćenje, motivaciju i potporu korisnički aktivnosti.

Empirijsko istraživanje predstavlja temelj za nastavak proučavanja faktora koji utječu na motivaciju i učenje ispitanika. Detaljna analiza trebala bi biti napravljena na **elementima računalnih igara** s ciljem kvantificiranja onih elemenata koji najviše utječu na unutarnju motivaciju polaznika, pri čemu je nemoguće obuhvatiti sve varijante koje se uočavaju vezano uz pitanja **uzrasta** i **spola** ispitanika, odgojno-obrazovnog **profila ispitanika**, **nastavnog područja** koje se predaje, **godine studija** i **stupnja obrazovanja**.

Unutarnja i vanjska motivacija vežu se uz iznimno mnogo faktora koje je sve nemoguće uključiti u istraživački rad. Buduća istraživanja trebala bi istaknuti **nedostatke** i **prednosti korištenja** elemenata računalnih igara u obrazovnim sustavima te ujedno približiti računalne igre **nastavnom osoblju** koje još uvijek ne shvaća ozbiljnost i veličinu **utjecaja računalnih igara na adolescente** i generaciju rođenu **nakon 2000. godine**.

Potrebno je provesti usporedno istraživanje vezano uz utjecaj na motivaciju i učenje ispitanika s obzirom na **cjelovite** računalne igre, sustave temeljene na **elementima** računalnih igara i **tradicionalne sustave** koji **ne sadržavaju** ni jedan element navedenog. Postavlja se pitanje koliko prosječni nastavnik u visokoškolskom obrazovanju ima **znanja o unutarnjoj i vanjskoj motivaciji**, **elementima računalnih igara** te **računalnim igrama u cijelosti**. Navedena pitanja iznimno su važna jer sustav mora imati podršku i razumijevanje osoblja, odnosno nastavnika koji ga koristi.

LITERATURA

Adam Stephen: *An introduction to learning outcomes: A consideration of the nature, function and position of learning outcomes in the creation of the European Higher Education Area*, Introducing Bologna objectives and tools, 2004.

Adeel J.M.: *The Benefits of Game Based Learning*, Microsoft Partners in Learning, 2014.

Aparicio F., Vela F.L.G., Sánchez J.L.G., Isla J.L.: Analysis and application of gamification, *ACM Interaccion '12.*, Elche, Alicante, Spain, 2012.

Awang N., Darus M.Y.: Evaluation of An Open Source Learning Management System: Claroline, *The 3rd International Conference on e-Learning ICEL2011*, str. 416–426, 2012.

Balogh Z., Turčáni M.: *Possibilities of Modelling Web-Based Education Using IF-THEN Rules and Fuzzy Petri Nets in LMS*, Informatics Engineering and Information Science, 2011.

Bandura A.: *Social Learning Theory*, Stanford University, General Learning Press, 1971.

Barata G., Gama S., Jorge J., Gonçalves D.: Engaging engineering students with Gamification, *5th International Conference on games and virtual worlds for serious applications, VSGAMES 2013.*, str. 24-31, Bournemouth, UK, 2013.

Barata G., Gama S., Jorge J., Gonçalves D.: Improving participation and learning with Gamification, *1st international conference on Gamification 2013.*, str. 9-16, Stratford, ON, Canada, 2013.

Barge P., Londhe, B.R.: *From Teaching, Learning to Assessment: MOODLE experience at B'School in India*, Symbiosis Institute of Management Studies Annual Research Conference, Economics and Finance 11, str. 857–865, 2014.

Bartle A.R.: *MUD Advanced Project Report*, an internal memorandum (CSM-73), Department of Computer Science's series, University of Essex, UK, 1985.

Bartle A.R.: *Players Who Suit MUDs*, a refereed paper, Journal of MUD Research, vol.1, br.1, 1996.

Behnke K.A.: Gamification in introductory computer science, doktorska disertacija, University of Colorado Boulder, 2015.

Bell B.S., Federman J.E.: *E-Learning in Postsecondary Education, The Future Of Children*, vol.23, br.1, Cornell University, 2013.

Berardi L., Rea M.A.: *E-learning for accountability in nonprofit organizations: A networked collaborative learning experience for managers of Blood Donors' organizations*, Social and Behavioral Sciences 2, str. 2126–2130, 2010.

Berryman S.E.: *Designing Effective Learning Environments: Cognitive Apprenticeship Model*, Institute on Education and the Economy, IEE Brief, br.1, 1991.

Bichsel J.: *The State of E-Learning in Higher Education: An Eye toward Growth and Increased Access*, Educause Center for Analysis and Research, Educause, 2013.

Bíró I.G.: *Didactics 2.0: A Pedagogical Analysis Of Gamification Theory From A Comparative Perspective With A Special View To The Components Of Learning*, Social and Behavioral Sciences 141, str. 148–151, 2014.

Bíró I.G.: Ready, Study, Share: An Inquiry Into The Didactic Approach Of Gamification With A Special View To The Possible Application In Higher Education, *1st Annual International Interdisciplinary Conference, AIIC 2013*, str. 24-26, Portugal, 2013.

Brown T.H.: The role of m-learning in the future of e-learning in Africa?, *21st International Council for Open and Distance Education, World Conference*, Hong Kong, 2003.

Browne K.: *Gamification of Mobile Educational Software*, doktorska disertacija, McMaster University, Hamilton, Ontario, 2016.

Bruke B.: *Gartner says get gamification working for you*, *Gartner Report*, Report ID:G00245563 (2013.) Dostupno na: <http://thisiswhatgoodlookslike.com/2013/03/24/gartner-says-get-gamification-working-for-you/>, pristupano 09.06.2016.

Burić H., Grubišić V.: *Online učenje hrvatskoga jezika na Sveučilištu Waterloo u Kanadi*, *Croatian Studies Review*, vol.6, 2010.

Calvillo-Gámez, E.H., Cairns P., Cox A.L.: *Assessing the Core Elements of the Gaming Experience*, *Evaluating User Experience in Games*, Human-Computer Interaction Series 4, Springer, 2010.

CARNet: *Biheviorizam*, dostupno na: www.carnet.hr/referalni/obrazovni/mkod/pedagogija/bihev.html, pristupano 20.6.2016.

CARNet: *Kognitivizam*, dostupno na: www.carnet.hr/referalni/obrazovni/mkod/pedagogija/kognit.html, pristupano 20.6.2016.

CARNet: *Konstruktivizam*, dostupno na: www.carnet.hr/referalni/obrazovni/mkod/pedagogijkonhtml, pristupano 20.6.2016.

Carvalho, A.A., Araújo I., Zagalo N.: A Framework For Gamified Activities Based On Mobile Games Played By Portuguese University Students, *International Conferences on Educational Technologies and Sustainability 2014*, Technology and Education 2014.

Cavaco I.N., Barreto L.de S., Monteiro A.C.C., da Silva D.R.D., Silva C.: *Gamification Aspects in Detail: Collectanea of Studies to Renew Traditional Education*, *Revista Eletrônica Argentina-Brasil de Tecnologias da Informação e da Comunicação*, vol.1, br.4, 2015.

Chou Y.: *Top 10 education gamification examples*, dostupno na: www.yukaichou.com/gamification-examples/top-10-education-gamification-examples, pristupano 28.04.2016.

Chou Y.: *Octalysis: Complete Gamification Framework*, dostupno na: <http://yukaichou.com/gamification-examples/Octalysis-complete-gamification-framework/>, pristupano 28.04.2016.

Chou Y.: *Why is gamification not included in Gartner's 2015 Hype Cycle?*, dostupno na: https://www.quora.com/Why-is-gamification-not-included-in-Gartners-2015-Hype-Cycle_, Quora 2016, pristupano 28.04.2016.

Clark D.: *Robert Gagné's Nine Steps of Instruction 2014.*, dostupno na: http://www.nwlink.com/~donclark/hrd/learning/id/nine_step_id.html, pristupano 20.4.2016.

Coates H., James R., Baldwin G.: *A Critical Examination Of The Effects Of Learning Management Systems On University Teaching And Learning*, Tertiary Education and Management 11, str. 19–36, 2005.

Collins A., Brown J.S., Newman S.E.: *Cognitive apprenticeship: Teaching the craft of reading, writing and mathematics*, L.B. Resnick (Ed) *Knowing, learning and instruction: Essays in honor of Robert Glaser*, str. 453-494, 1989.

Costa C., Alvelos H., Teixeira L.: The use of Moodle e-learning platform: a study in a Portuguese University, *Conference on ENTERprise Information Systems*, Technology 5, str. 334-343, 2012.

Csikszentmihalyi M., LeFevre J.: *Optimal Experience in Work and Leisure*, Journal of Personality and Social Psychology, vol.56, br.5, str. 815-822, 1989.

Csikszentmihalyi M., Nakamura J.: *The Concept of Flow*, Handbook of positive psychology, str. 89-105, 2002.

Ćukušić M., Jadrić M.: *e-učenje: koncept i primjena*, Školska knjiga, 2012.

Čizmešija Aleksandra: *Uvod u ishode učenja*, Inter-Outcomes 2008., dostupno na: http://iu.foi.hr/upload_data/dokumenti/diseminacija/UvodUIshodeUcenja.pdf, pristupano: 20.12.2016.

De-Marcos L., Domínguez A., Saenz-de-Navarrete J.: *Carmen Pagés: An empirical study comparing gamification and social networking on e-learning*, Computers & Education 75, str. 82–91, 2014.

De Vitte F., Tabak, M., Dekker, M., Vollenbroek-Hutten, M.: *Increasing Motivation In eHealth Through Gamification*, University of Twente, 2015.

Deterding S.: *Gamification: Designing for Motivation*, Magazine interaction, vol.19, br.4, str. 14–17, USA, 2012.

Deterding S.: *The Lens of Intrinsic Skill Atoms: A Method for Gameful Design*, Human–Computer Interaction, vol.30, str. 294-335, 2015.

Deterding S., Dixon D., Khaled R., Nacke L.: From game design elements to gamefulness: Defining gamification, *15th International Academic MindTrek Conference: Envisioning Future Media Environments*, str. 9-15, USA, 2011.

Dharmawansa A.D., Nakahira K.T., Fukumura Y.: Detecting eye blinking of a real-world student and introducing to the virtual e-Learning environment, *17th International Conference in Knowledge Based and Intelligent Information and Engineering Systems*, str. 717–726, 2013.

Diaz L.A.jr.: *The Gamification of Judicial Affairs: Addressing Learning for 'Digital Students'*, Faculty of the USC Rossier School of Education, University of Southern California, 2012.

Dicheva D., Dichev C., Agre G., Angelova G.: *Gamification in Education: A Systematic Mapping Study*, *Educational Technology & Society*, vol.18, br.3, 2015.

Divjak B. i suradnici: *Ishodi učenja u interdisciplinarnim studijskim programima*, Inter-Outcomes, Varaždin 2009., dostupno na: http://www.iu.foi.hr/index.php/dokumenti/upload_data/knjiga/Ishodi_ucenja_u_visokom_obrazovanju_12122008_F.pdf, pristupano: 20.12.2016.

Economou D., Doumanis I., Pedersen F., Kathrani P., Mentzelopoulos M., Bouki V.: Evaluation of a dynamic role-playing platform for simulations based on *Octalysis* gamification framework, *11th International Conference on Intelligent Environments*, 2015.

El-Khuffash A.: *Gamification, Major Research Paper*, Ted Rogers School of Management, Ryerson University, Toronto, Canada, 2015.

Ergle D.: AirBaltic Case Based Analysis of Potential for Improving Employee Engagement Levels in Latvia through Gamification, *Scientific Conference on Economics and Entrepreneurship*, 2015.

Erjavec Zlatko: *Kako odrediti ishode učenja kolegija?*, Inter-Outcomes 2008., dostupno na: http://iu.foi.hr/upload_data/dokumenti/diseminacija/KakoOdreditiIshodeUcenjaKolegija.pdf, pristupano: 20.12.2016.

Esteban-Millat I., Martínez-López F., Huertas-García R., Meseguer A., Rodríguezardura I.: *Modelling students' flow experiences in an online learning environment*, *Computers & Education* 71, str. 111–123, 2014.

EU-IPA IV: *Razvoj vještina kroz e-učenje: New skills for new job opportunities*, dostupno na: www.instruktazni.hr/html/preuzimanja/eu/razvoj-vjestina-%20kroz-e-ucenje-skripta.pdf, pristupano 20.4.2016.

Fallon C., Brown S.: *E-learning standards: a guide to purchasing, developing, and deploying standards-conformant e-learning*, CRC Press, Boca Raton, Florida, 2002.

Friedland G., Hürst W., Knipping L.: Educational Multimedia Systems: The Past, the Present, and a Glimpse into the Future, *Educational Multimedia and Multimedia Education 2007.*, Augsburg, Bavaria, Germany, 2007.

Fu F.L., Su R.C., Yu S.C.: *EGameFlow: A scale to measure learners' enjoyment of e-learning games*, *Computers & Education* 52, str. 101–112, 2009.

Fry Kate: *E-learning markets and providers: some issues and prospects*, *Education+ Training*, br. 43 izdanje: 4/5, str. 233-239, 2001.

Gaebel M., Kupriyanova V., Morais R., Colucci E.: *E-Learning In European Higher Education Institutions*, European University Association publications, 2014.

Gamification Summit: *San Francisco 2014*. Dostupno na: <http://sf14.gsummit.com/>, pristupano 1.7.2016.

Gardner C., Amoroso D.L.: Development of an Instrument to Measure the Acceptance of Internet Technology by Consumers, *37th Hawaii International Conference on System Sciences, USA, 2004*.

Gil B., Cantador I.: On The Development Of Gamified Activities In The Classroom, *II. International Workshop on Gamification in Education: gEducation 2015*, Spain 2015.

Goasduff L., Pettey C.: *Gartner says by 2015, more than 50 percent of organizations that manage innovation processes will gamify those processes*, Egham, UK, 2011., dostupno na: <http://www.gartner.com/newsroom/id/1629214>, pristupano 1.7.2016.

Gogan M.L., Sirbu R., Draghici A.: *Aspects Concerning the use of the Moodle Platform - Case Study*, Technology 19, str. 1142-1148, 2015.

González-González C.S., Toledo-Delgado P., Padrón M., Santos E., Cairos M.: *Including Gamification Techniques in the Design of TANGO: H Platform*, Penerbit UTM, Tenerife, Spain, 2013.

González-González C.S., Carreno A.M.: Methodological proposal for Gamification in the Computer Engineering Teaching, *International Symposium on Computers in Education, University of La Laguna, Tenerife, Spain, 2014*.

Gamification World Conference GWC, dostupno na www.gwc-conference.com/gwc-2016/, pristupano 1.7.2016.

Hakulinen Lasse: *Gameful Approaches for Computer Science Education: From Gamification to Alternate Reality Game*, doktorska disertacija, Department of Computer Science, Aalto University publications series 52/2015., Finland, 2015.

Hamari J.: Gamification: Motivations & Effects, doktorska disertacija, Aalto University publications series 11/2015., Finland, 2015.

Hamari J., Koivisto J.: *Measuring flow in gamification: Dispositional Flow Scale*, Computers in Human Behavior 40, str. 133–143, 2014.

Hamari J., Koivisto J., Sarsa H.: Does Gamification Work? - A Literature Review of Empirical Studies on Gamification, *47th Hawaii International Conference on System Sciences*, str. 6-9, USA, 2014.

Hamari J., Parvinen P.: Introduction to Gamification: Motivations, Effects and Analytics, *49th Hawaii International Conference on System Sciences*, Koloa, USA, 2016.

Hendriks M.: *Gaming the system: Making personalised learning fun*, Master Thesis Computer Science, Sveučilište Radboud Nijmegen, 2015.

Hošková-Mayerová Š., Rosická, Z.: *E-Learning Pros And Cons: Active Learning Culture?*, Social and Behavioral Sciences 191, str. 958–962, 2015.

Hrvatski Kvalifikacijski Okvir: *Vodič za korisnike ECTS-a*, Zagreb, Europska unija 2015., dostupno na: www.kvalifikacije.hr/fgs.axd?id=1172, pristupano: 20.12.2016.

Huang, Y., Backman, S.J., Backman, K.F., Moore, D.: *Exploring user acceptance of 3D virtual worlds in travel and tourism marketing*, Tourism Management 36, str. 490-501, 2013.

Hussain F.: *E-Learning 3.0 = E-Learning 2.0 + Web 3.0?*, *International Conference on Cognition and Exploratory Learning in Digital Age*, 2012.

ICT 2014 - Information and Communications Technologies, Sub call of: H2020-ICT-2014, dostupno na: <http://ec.europa.eu/research/participants/portal/desktop/en/opportunities/h2020/topics/90-ict-21-2014.html#tab2>, pristupano 09.06.2016.)

ICT 2016 - Information and Communications Technologies, Sub call of: H2020-ICT-2016, dostupno na: <https://ec.europa.eu/research/participants/portal/desktop/en/opportunities/h2020/topics/5088-ict-24-2016.html>, pristupano 09.06.2016.)

Iosup A., Epema D. An Experience Report on Using Gamification in Technical Higher Education, *CM Technical Symposium on Computer Science Education*, str. 27-32, USA, 2014.

Jayasinghe U., Dharmaratne A.: Game Based Learning vs. Gamification from the higher education students' perspective, *IEEE International Conference on Teaching, Assessment and Learning for Engineering*, University of Colombo School of Computing, Sri Lanka, 2013.

Juhary J.: Making Sense of e-Learning and Simulations: The Misunderstood Perceptions, *3rd International Conference on e-Learning 2011*, str. 229–237, 2012.

Kearsley G., Culatta R.: *Dual Coding Theory*, InstructionalDesign.org, dostupno na: www.instructionaldesign.org/theories/dual-coding.html, pristupano 20.4.2016.

Kearsley G., Culatta R.: *Anchored instruction*, InstructionalDesign.org, dostupno na: www.instructionaldesign.org/theories/anchored-instruction.html, pristupano 20.6.2016.

Kearsley G., Culatta R.: *Elaboration theory*, InstructionalDesign.org, dostupno na: www.instructionaldesign.org/theories/elaboration-theory.html, pristupano 20.6.2016.

Kearsley G., Culatta R.: *Social learning Theory*, InstructionalDesign.org, dostupno na: www.instructionaldesign.org/theories/social-learning.html, pristupano 20.6.2016.

Kim A.J.: *Gamification 101: Design the Player Journey 2011.*, dostupno na: de.slideshare.net/amyjokim/gamification-101-design-the-player-journey, pristupano 09.03.2016.)

Kim J.T., Lee W.H.: *Dynamical model for gamification of learning (DMGL)*, International Journal of Multimedia and Ubiquitous Engineering, vol.8, br.4, 2013.

Klement M., Dostál J.: *Students and e-learning: a longitudinal research study into university students' opinions on e-learning*, Social and Behavioral Sciences 128, str. 175–180, 2014.

Kovacova L., Vackova M.: *Implementation of E-Learning Into The Process Security Education In Universities*, Social and Behavioral Sciences 182, str. 414–419, 2015.

Kovačević I., Minović M., Milovanović M., de Pablosb P.O., Starčević D.: *Motivational aspects of different learning contexts: "My mom won't let me play this game..."*, Computers in Human Behavior 29, str. 354–363, 2013.

Krpan D.: *Modeliranje grupe u sustavima za e-učenje*, Prirodoslovno - matematički fakultet, Sveučilište u Splitu, 2010.

Kuleto V., Dedić V.: *E-učenje, E-learning: Razvoj - Tehnologija - Budućnost*, INK group DOO, Beograd, 2014.

Kumar J., Herger M.: *Gamification at Work: Designing Engaging Business Software*, dostupno na www.interaction-design.org/literature/book/gamification-at-work-designing-engaging-business-software, Interaction Design Foundation, Denmark, 2013., pristupano 4.7.2016.

Kurt S.: Use of constructivist approach in architectural education, *3rd World Conference on Educational Sciences*, Istanbul, Turkey, 2011.

Landers R.N., Callan R.C.: *Casual social games as serious games: The psychology of gamification in undergraduate education and employee training*, Serious Games and Edutainment Applications, London 2011.

Laskowski M., Badurowicz M.: *Gamification in higher education: a case study*, Human Capital without Borders: Knowledge and Learning for Quality of Life, Portorož, Slovenia, 2014.

LeHong H., Fenn J.: *Key Trends to Watch in Gartner 2012 Emerging Technologies Hype Cycle*, Gartner Inc. 2012. Dostupno na: www.forbes.com/sites/gartnergroup/2012/09/18/key-trends-to-watch-in-gartner-2012-emerging-technologies-hype-cycle-2, pristupano 4.7.2016.

Liboriussen B., Martin P.: *Special Issue: Games and Gaming in China, Games and Culture 2016*, vol.11, br.3, str. 227-232, Ningbo, China, 2016.

Liu S., Liao H., Pratt J.A.: *Impact of media richness and flow on e-learning technology acceptance*, Computers & Education 52, str. 599–607, 2009.

Lombriser P.: *Engaging Stakeholders in Scenario-Based Requirements Engineering with Gamification*, Master Thesis, Sveučilište Utrecht, 2015.

Lovett M.: *Theory and Research-based Principles of Learning*, Eberly Center for Teaching Excellence and Educational Innovation, Carnegie Mellon, 2016. Dostupno na: <https://www.cmu.edu/teaching/principles/learning.html>, pristupano 4.7.2016.

Ludvigsen M. i Wallervand C.: *Gamifying an Oil-Gas-Water Separation Process in a Process Control System to Improve Operators' Motivation, Skills, and Process Understanding*, Norwegian University of Science and Technology, 2012.

Malone T.W, Lepper M.R.: *Making learning fun: a taxonomy of intrinsic motivations for learning*, Snow RE, Farr MJ Aptitude, learning and instruction III, 1987.

Marczewski A.: *A New Perspective on the Bartle Player Types for Gamification (2013.)*, dostupno na: gamification.co/2013/08/12/a-new-perspective-on-the-bartle-player-types-for-gamification, pristupano 09.06.2016.

Marczewski A.: Marczewski's User Type Test (2016.), dostupno na: www.gamified.uk/UserTypeTest/user-type-test.php#.VnlBirbhBpQ, pristupano 09.06.2016.

Marczewski A.: *Understanding Intrinsic Motivation with RAMP (2013.)*, dostupno na: www.gamification.co/2013/05/01/understanding-intrinsic-motivation-with-ramp/, pristupano 09.06.2016.

Markova Y.: *Applicability Of The Concept "Gamification" Within Business Organizations, Master Programme Business Administration – Strategic Management*, Sveučilište St. Kliment Ohridski, Sofia, 2013.

Mayo J.M.: *Games For Science And Engineering Education*, Communications Of The ACM, vol.50, br.7., USA, 2007.

McGonigal J.: *Reality is Broken: Why Games Make Us Better and How They Can Change the World*. New York, NY: Penguin Press, 2011.

McGuire M.: *Hype Cycle: Digital Marketing*, dostupno na: gartner.com/doc/3096618/hype-cycle-digital-marketing-, Gartner, 2015., pristupano 09.03.2016.

McLeod S., Vygotsky L.: *Social Learning Theory*, Simply Psychology, 2014., dostupno na: <http://www.simplypsychology.org/vygotsky.html>, pristupano 20.4.2016.

Melânia F.: *Implementation Of E - Learning In To OHS Education*, Social and Behavioral Sciences 191, str. 1275–1281, 2015.

Michael W.: *Gamification 101: The Psychology of Motivation*, Lithium, USA 2012.

Mihaljišin M.: *E-učenje, Komunikacije u savremenom društvu*, dostupno na: <http://paperzz.com/download/5170481>, pristupano 20.4.2016.

Mohammadi N., Ghorbani V., Hamidia F.: *Effects of e-learning on Language Learning*, Computer Science 3, str. 464–468, 2011.

Moore J.L., Dickson-Deane C., Galyen K.: *e-Learning, online learning, and distance learning environments: Are they the same?*, Internet and Higher Education 14, str. 129–135, 2011.

Mozhaeva G., Feshchenko A., Kulikov I.: *E-learning in the evaluation of students and teachers: LMS or social networks?*, Social and Behavioral Sciences 152, str. 127–130, 2014.

Muntean C.I.: Raising engagement in e-learning through gamification, *The 6th International Conference on Virtual Learning ICVL, 2011*.

Nielson B.: *Gamification Mechanics vs. Gamification Dynamics*, Your Training Edge, 2013.

Octalysis Online alat, dostupan na: <http://www.yukaichou.com/Octalysis-tool/>, pristupano travanj 2016., pristupano 09.05.2016.

Oproiu G.C.: *A Study about Using E-learning Platform (Moodle) in University Teaching Process*, The 6th International Conference Edu World, Social and Behavioral Sciences 180, str. 426–432, 2015.

Ortega de M. L., Domínguez A., Saenz-de-Navarrete J.: *An empirical study comparing gamification and social networking on e-learning*, Computer Science Department, Sveučilište Alcalá, Computers & Education 75, str. 82–91, 2014.

Ortiz G.: Neuropsicología aplicada a la gerontología: “una perspectiva integradora para el abordaje del adulto mayor” - Solenny López, dostupno na <http://neuromosobe.blogspot.hr/>, pristupano: 17.01.2017.

Owen J., Warren A.,A.: *Generation Z – What To Expect, What They Expect*, Interactive Classroom, Texas Southern University, 2016., dostupno na: <http://digitalscholarship.tsu.edu/swbatc/2016/Interactive/3/>, pristupano: 14.02.2017.

Paechter M., Maier B., Macher D.: *Students' expectations of and experiences in e-learning: their relation to learning achievements and course satisfaction*, Computers and Education 54, str. 222-229, 2010.

Parnell M.J.: *Playing with Scales: Creating a Measurement Scale to Assess the Experience of Video Games*, Human-Computer Interaction with Ergonomics, University College London, 2009.

Parreno J.M., Mas D.S, Mas E.S.: Teachers' attitude towards and actual use of gamification, *2nd International Conference on Higher Education Advances*, València, Spain, Social and Behavioral Sciences 228, str. 682-688, 2016.

Pedreira O., García F., Brisaboa N., Piattini M.: *Gamification in software engineering – A systematic mapping*, Information and Software Technology 57, str. 157–168, 2015.

Pejičić A.: *E-Learning*, diplomski rad, Sveučilište Singidunum, Beograd, 2011.

Pelling N.: *The (short) prehistory of “gamification”* dostupno na nanodome.wordpress.com/2011/08/09/the-short-prehistory-of-gamification 2011., pristupano 09.03.2016.

Pereira F.A.M., Ramos A.S.M., Gouvêa M.A., da Costa M.F.: *Satisfaction and continuous use intention of e-learning service in Brazilian public organizations*, Computers in Human Behavior 46, str. 139–148, 2015.

Petridis P., Baines T., Hadjicosta K., Dunwell I., Lameris P.: *Gamification: Using Gaming Mechanics to Promote a Business*, Proceedings of the Spring Servitization Conference, Sveučilište Aston, Birmingham, UK, 2014.

Phobun P., Vicheanpanya, J.: *Adaptive intelligent tutoring systems for e-learning systems*, Social and Behavioral Sciences 2, str. 4064–4069, 2010.

Poulova P., Simonova I., Manenova M.: Which One, or Another? Comparative Analysis of Selected LMS, *5th World Conference on Learning, Teaching and Educational Leadership, WCLTA 2014.*, str. 1302–1308, 2015.

Presnell F.: *Jean Piaget: Biography (1999.)*, dostupno na: www.muskingum.edu/~psych/psycweb/history/piaget.htm, pristupano 20.4.2016.

Radoff, J.: *Game on: energize your business with social media games*, str. 24–32, Wiley, 2011.

Ragupathi K. *Gamification: How to do it Right and Why it is No Good*, Technology in Pedagogy, br.13, 2012.

Rajić V.: *Samoaktualizacija, optimalna iskustva i reformske pedagogije*, Pregledni članak, Učiteljski fakultet Sveučilišta u Zagrebu, Zagreb, 2011.

Ramar V., Agarwal K.K., Loganathan M., Krishnan A.R.: *Perception on the Role of Teachers in Managing Talents of Generation Z Students*, Indian Journal of Science and Technology vol.9, broj 36, India, 2016.

Ramar V., Sayan B., Singh R.A., Aaratrika C.: *Generation Z Students' Talent Management: Unveiling Talents of Student CEOs in Creating Student Superstars*, Indian Journal of Science and Technology vol.9, broj 39, India, 2016.

Rasmussen G.: *Creative Expression As The Objective In Video Games*, Faculty of Creative Industries, University of Technology Queensland, 2014.

Rauch, M.: *Gamification is Here: Build a Winning Plan*, STC Intercom, Society for Technical Communication, str. 7–12, 2012.

Reinemeyer E.: *Edward Lee Thorndike, Biography (1999.)*, dostupno na: www.muskingum.edu/~psych/psycweb/history/thorndike.htm, pristupano 20.4.2016.

Ryan R., Deci E. i suradnici: *Self-Determination Theory questionnaires*, Sveučilište Rochester, USA, 2015.

Sæter S.L.; Valle B.: *Promotion of Reflective Learning through Gamification*, Master Thesis, Faculty of Information Technology, Mathematics and Electrical Engineering, 2013.

Sailer, M., Hense, J., Mandl, H., Klevers, M.: *Psychological Perspectives on Motivation through Gamification*, Interaction Design and Architecture(s) Journal - IxD&A, vol.19., str. 28-37, 2013.

Schönen R.: *Gamification in Change Management processes: An empirical research by means of qualitative methods to analyze relevance, implications and selected use cases*, Bachelor Thesis, University of Applied Sciences Munich, 2014.

Schonfeld E.: *SCVNGR's Secret Game Mechanics Playdeck*, dostupno na: techcrunch.com/2010/08/25/scvngr-game-mechanics, 2010., pristupano 09.03.2016.

Schreuders Z.C., Butterfield E.: *Gamification for Teaching and Learning Computer Security in Higher Education*, *USENIX Workshop on Advances in Security Education*, Austin, Texas, 2016.

Seaborn K., Fels D.I.: *Gamification in theory and action: A survey*, Int. J. Human-Computer Studies 74, str. 14–31, 2015.

Shroff, R.H., Deneen, C.C., Ng, E.M.W.: *Analysis of the technology acceptance model in examining students' behavioural intention to use an e-portfolio system*, Australasian Journal of Educational Technology 27, str. 600-618, 2011.

Simuth, J., Sarmany-Schuller I.: *Principles for e-pedagogy*, *World Conference on Educational Sciences 2012*, str. 4454–4456, 2012.

Singer L.G.: *Improving the Adoption of Software Engineering Practices Through Persuasive Interventions*, Gottfried Wilhelm Leibniz Universität Hannover, 2013.

Smith M.K.: *Howard Gardner and multiple intelligences*, The Encyclopedia of Informal Education 2008. dostupno: <http://infed.org/mobi/howard-gardner-multiple-intelligences-and-education/>, pristupano 20.6.2016.

Smith M.K.: *Jerome Bruner and the process of education*, The Encyclopedia of Informal Education 2002. dostupno: infed.org/mobi/jerome-bruner-and-the-process-of-education/, pristupano 20.6.2016.

Smole K.S., Diniz M.I., Milani E.: *Math games from 6 to 9 grade*, *Math computer games*. New York: Guilford Press, USA 2007.

Sørebo Ø., Halvari H., Gulli V.F., Kristiansen R.: *The role of self-determination theory in explaining teachers' motivation to continue to use e-learning technology*, Computers & Education 53, str. 1177–1187, 2009.

Souza-Concilio I.A.; Pacheco B.A.: *Games and Learning Management Systems: A Discussion about Motivational Design and Emotional Engagement*, SBGames (2013.)

Stahl G., Koschmann T., Suthers D.: *Computer-supported collaborative learning: An historical perspective*, Cambridge handbook of the learning sciences, str. 409-426, Cambridge, UK, 2006.

Stavrakakis I., Bagnoli F., Guazzini A., Theodorakopoulos G., Kokolaki E.: *Foundations for Collective Awareness Platforms: Collective Awareness Platforms: Privacy, incentives, and market dimensions*, FP7 project – 288021, FOCAL, 2015.

Stokes Z.: *Integration of Gamification into the Classroom and the Reception by Students*, Marshall Digital Scholar: Theses, Dissertations and Capstones, Paper 8562014, 2014.

Sveučilišni računski centar (SRCE): *E-učenje*, Sveučilište u Zagrebu, dostupno na: www.srce.unizg.hr/ceu/o-centru/e-ucenje/, pristupano 30.03.2016.

Sveučilište u Rijeci: *Strategija razvoja Sveučilišta u Rijeci 2014-2020*.

Sveučilište u Rijeci: *Strategija uvođenja e-učenja na Sveučilištu u Rijeci 2006-2010*.

Sveučilište u Splitu: *Strategija razvitka za razdoblje 2011-2015*.

Sveučilište u Splitu: *Strategija Sveučilišta u Splitu 2015-2020*.

Sveučilište u Zadru: *Strategija Sveučilišta u Zadru 2011-2017*.

Sveučilište u Zadru: *Strategija Sveučilišta u Zadru 2015-2019*.

Sveučilište u Zagrebu: *Strategija e-učenja 2007-2010*.

Swenson C.: *Burrhus Frederick Skinner, Biography (1999.)*, dostupno na: www.muskingum.edu/~psych/psycweb/history/skinner.htm, pristupano 20.4.2016.

Taspinar B., Schmidt W., Schuhbauer H.: Gamification in education: a board game approach to knowledge acquisition, *International Conference on Knowledge Management*, Vienna, Austria, Computer Science 99, 101 – 116, 2016.

Tîrziu A.M., Vrabie C.: Education 2.0: E-Learning Methods, *5th World Conference on Learning, Teaching and Educational Leadership, WCLTA 2014*, str. 376 – 380, 2015.

Tomić D.: *Učinci primjene edukativnih računalnih igara u nastavi matematike*, doktorska disertacija, Fakultet organizacije i informatike, Varaždin, 2012.

Truskolaska J., Łuka M., Toruj N., Wrona K., Smagowska P.: *E-learning at the polish university in the opinion of students*, Social and Behavioral Sciences 191, str. 3494–3499, 2015.

Učenje na daljinu: Priručnik za učenje na daljinu za voditelje, mentore i autore e-tečaja, Pravosudna akademija Republike Hrvatske (2014.)

Van den Berg C.: *Gamify a Contact Center*, Master Thesis, Sveučilište u Amsterdamu, 2014.

Van der Meulen J., Rivera R.: *Gartner's 2013 Hype Cycle for Emerging Technologies Maps Out Evolving Relationship Between Humans and Machines*, Stamford, 2013.

Vehns M.: *The application of gamification in sales*, Master's Thesis, Sveučilište u Južnom Walesu, Cardiff, 2014.

Versteeg C.: *Ethics & Gamification design a moral framework for taking responsibility*, New Media & Digital Culture, 2013.

Vlada Republike Hrvatske: *Strategija obrazovanja, znanosti i tehnologije*, 2014.

Von Schiller F.C.: *Gamification Of Management Control Systems - Opportunities And Limitations In Germany*, Bachelor Thesis, Faculty of the Berlin School of Economics and Law, 2015.

Vygotskaya G., Veresov N.: *The Vygotsky Project 2001.*, dostupno na: <http://webpages.charter.net/schmolze1/vygotsky/vygotsky.html>, pristupano 20.5.2016.

Watson E.: *John B. Watson, Biography (1999.)*, dostupno na: www.muskingum.edu/~psych/psycweb/history/watson.htm, pristupano 20.4.2016.

Webb E.N.: *Gemification in enterprise: Gartner Hype Cycles 2013*. Gartner Inc., 2013., dostupno na: gartner.com/newsroom/id/2575515, pristupano 09.03.2016.

Werbach K., Hunter D.: *For the Win: How Game Thinking Can Revolutionize Your Business*, Wharton Digital Press, Sveučilište Pennsylvania, Philadelphia, 2012.

Williams J.B., Goldberg M.: The evolution of e-learning, Balance, Fidelity, Mobility: maintaining the momentum?, *Ascilite Conference Proceedings*, 2005.

Wu M.: *Gamification from a Company of Pro Gamers (2011.)*, dostupno na: community.lithium.com/t5/Science-of-Social-blog/Gamification-from-a-Company-of-Pro-Gamers/ba-p/19258, pristupano 09.03.2016.

Xu Y.: *Literature Review on Web Application Gamification and Analytics*, Collaborative Software Development Laboratory Technical Report, 11-05, Sveučilište Hawaii, 2011.

Yacob A., Kadir A.Z.A., Zainudin O., Zurairah A.: Student Awareness Towards E-Learning In Education, *The 3rd International Conference on e-Learning ICEL 2011*, str. 93–101, 2012.

Yana M.: *Applicability of the concept “gamification” within business organizations*, Master Thesis at University St. Kliment Ohridski, Faculty of Economics and Business Administration, Sofia, 2013.

Zachary F.W.: *Achievement Unlocked: Investigating the Design of Effective Gamification Experiences for Mobile Applications and Devices*, doktorska disertacija, Science and Engineering Faculty, University of Technology Queensland, 2015.

Zhang D.: *Powering E-Learning In the New Millennium: An Overview of E-Learning and Enabling Technology*, *Information Systems Frontiers* 5, str. 201–212, 2003.

Zichermann G; Linder J.: *Game-based marketing*, str. 19–20, str. 43–44. Wiley, 2010.

Zichermann G., Cunningham C.: *Gamification by Design: Implementing Game Mechanics in Web and Mobile Apps*, O'Reilly Media, Inc., 2011.

PRILOZI

PRILOG 1. PRIMJERI DOKUMENATA ISTRAŽIVAČKOG RADA

Sveučilište u Zagrebu
Fakultet organizacije i informatike
Pavlinska 2
42000 Varaždin

UPRAVI

REPUBLIKA HRVATSKA			
2186-62 Fakultet organizacije i informatike			
VARAŽDIN			
Primijeno:	16.11.15		
Klasifikacijska oznaka	05-02	15-0311	Org. jed.
Uredbeni broj	U86-02/4-15-104	Prih.	Vrij.

Andrija Bernik
091 432 0203
42000 Varaždin
andrija.bernik@foi.hr
Ruđera Boškovića 14

16. studeni 2015.

ZAMOLBA ZA PROVOĐENJE ISTRAŽIVANJA

Poštovani,

molio bih Vas za dopuštenje za uključivanje studenata koji pohađaju kolegij "Računalom posredovana komunikacija" na diplomskom studiju na Fakultetu organizacije i informatike u Varaždinu u istraživački rad za potrebe izrade doktorske disertacije. Istraživanje bi se sastajalo od dvije pisane provjere znanja i anketnog upitnika, kao i samostalnog rada studenata sa jednim poglavljem Moodle tečaja o multimedijskoj komunikaciji, koja je jedna od tematskih cjelina u kolegiju, u trajanju od 2-3 tjedna.

Prva pisana provjera usmjerena je provjeri studentovog predznanja. Druga pisana provjera usmjerena je provjeri znanja iz određene nastavne cjeline nakon korištenja eksperimentalne verzije Moodle sustava. Anketni upitnik usmjeren je povratnoj informaciji koju će dobiti od studenata o eksperimentalnom Moodle sustavu i prikupljanju mišljenja o motivirajućim elementima računalnih igara.

Ranija istraživanja provedena su ove akademske godine na kolegiju "3D modeliranje", Odjela multimedijske, oblikovanja i primjene, Sveučilišta Sjever, kao i kolegija "Programiranje 2", Fakulteta organizacije i informatike.

Premda istraživanje nije anonimno, ono ne zadire u osobnu domenu studenata, niti će se koristiti u bilo koju drugu svrhu izvan ovog istraživanja. Istraživanje ne remeti tijek nastave niti uključuje izmijenjene nastavne materijale. Upitnik ispituje samo doživljavanje i način rada sa e-tečajem.

U istraživanju se stvaraju dvije skupine ispitanika, eksperimentalna i kontrolna. Pritom bi se eksperimentalna grupa uključila u rad sa novim gemificiranim Moodle sustavom koji bi sadržavao što je više moguće motivirajućih elemenata računalnih igara kao što su: bedževi, personalizacija profila, vizualan status obveza i napretka, "top lista uspjeha", izmijenjeno grafičko sučelje, skriveni i bonus nastavni materijali, i dr. Kontrolna grupa radila bi sa tradicionalnim negemificiranim Moodle tečajem.

Naslov odobrene teme disertacije je "Uvođenje elemenata računalne igre u online poučavanje sadržaja informatičkih nastavnih predmeta", a mentori su prof. dr.sc. Goran Bubaš i izv.prof. dr.sc. Danijel Radošević.

Radna verzija anketnog upitnika i prvi test nalazi se u prilogu.
Hvala Vam na razmatranju ove zamolbe.

U Varaždinu, 16.11.2015.

S poštovanjem,
Andrija Bernik

Bernik

Suglasan:

Prof.dr.sc. Goran Bubaš
(nositelj kolegija RPK)

Goran Bubaš

*Odobreno je
u Varaždinu, 19.11.2015.*

Slika A. Primjer zamolbe za odobrenje aktivnosti drugog glavnog istraživanja

Poštovane kolegice i kolege, u nastavku su upute za pristup **Moodle sustavu sa dodatnim materijalima**:

1. Poveznica za sustav je: <http://elf.foi.hr/course/view.php?id=404>
2. Otvara se prozor za prijavu:

foi
FOI Prijava

Enter your Username and Password

Username:

Password:

Warn me before logging me into other sites.

LOGIN clear

For security reasons, please Log Out and Exit your web browser when you are done accessing services that require authentication! Before entering your NetID and password, verify that the URL for this page begins with: <https://login.foi.hr/>

You do not have a username or have forgotten your password? Contact [CIP](#). You can change your password [here](#).

Unauthorized access or misuse of computer resources or disclosure of sensitive information may result in disciplinary or legal action. Read FOI's [Regulation on the disciplinary responsibility of students](#).

Languages: [English](#) | [Croatian](#)

Copyright © 2011-2015 Faculty of Organization and Informatics, University of Zagreb
Powered by [Jasig Central Authentication Service 3.5.2](#)

3. Logirajte se sa Vašim **@AAI računom**
4. Otvara se Moodle kolegij pod nazivom: **Programiranje OM**
 - Lozinka za kolegij je: **lozinka**
 - U navedenom sustavu nalaze se bonus materijali iz programiranja 2

ELF 2015/2016 Hrvatski (hr) -

foi
Fakultet Organizacije i Informatike
Vukovar

Moja naslovnica ► Razno ► Programiranje OM

NAVIGACIJA

Moja naslovnica

- Naslovnica sustava
- Stranice na razini sustava
- ▼ Trenutni e-kolegiji
- ▼ Programiranje OM
 - Sudionici
 - Značke
 - Opći dio
 - Tema 1
 - Tema 2
- Moji e-kolegiji

POSTAVKE

- ▼ Administracija e-kolegija
 - Omogući izmjene
 - Uredi postavke
 - Dovršenost e-kolegija
 - Korisnici
 - Filtri
 - Izvješćaji
 - Ocjene
 - Ishodi učenja
 - Značke
 - Backup
 - Vraćanje iz kopije

Obavijesti

- Ishodi učenja
- Popis pojnova

Tema 1

- Poglavlje 1a - Hrpa
- Poglavlje 2a - Punjenje i Implementacija hrpe pomoću polja
- Poglavlje 3a - Brisanje korijena i Implementacija hrpe pomoću cjelobrojnog polja
- Poglavlje 4a - Punjenje hrpe
- Poglavlje 5a - Uzastopno brisanje korijena hrpe (Heapsort)
- Stari i novi nazivi standardnih biblioteka jezika C++

Tema 2

- Poglavlje 1b - Stog
- Poglavlje 2b - Dodavanje (PUSH), očitavanje i brisanje vrha stoga (POP)
- Poglavlje 3b - Dodavanje (PUSH), očitavanje i brisanje vrha stoga (POP)

PRETRAŽI FORUME

Kreni

Napredno pretraživanje

NOVE OBAVIJESTI

Dodajte novu temu...

(Trenutno nema obavijesti)

BUDUĆA DOGAĐANJA

Nema predstojećih događaja

Prikaži kalendar...

Novi događaj...

NEDAVNA AKTIVNOST

Aktivnost od Wednesday, 14 October 2015, 20:31

Potpuni izvješćaj o nedavnoj aktivnosti...

Nema novosti od vaše zadnje prijave u sustav

5. Pročitajte i proučite priložene materijale.

Slika B. Primjer uputa za *kontrolnu* grupu ispitanika za *prvo glavno istraživanje*

Opis sustava koji Vas čeka nalazi se u nastavku ovog dokumenta:

1. Poveznica za **GMoodle**: <https://moodle2...hr/>
2. Otvara se:



This Connection is Untrusted


You have asked Firefox to connect securely to **moodle2.vz.unin.hr**, but we can't confirm that your connection is secure.

Normally, when you try to connect securely, sites will present trusted identification to prove that you are going to the right place. However, this site's identity can't be verified.

What Should I Do?

If you usually connect to this site without problems, this error could mean that someone is trying to impersonate the site, and you shouldn't continue.

▶ **Technical Details**

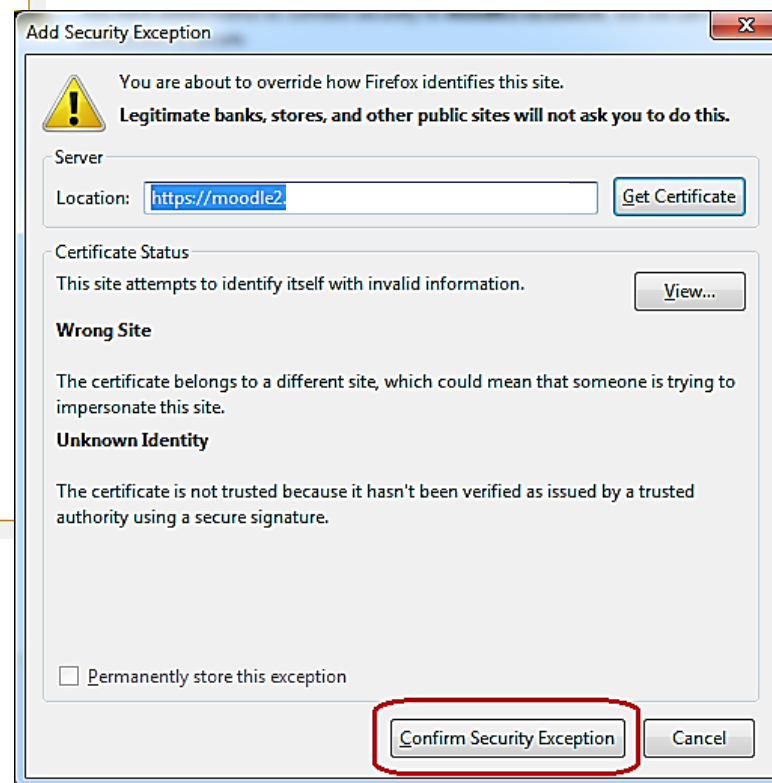
▼ **I Understand the Risks** 

If you understand what's going on, you can tell Firefox to start trusting this site's identification. **Even if you trust the site, this error could mean that someone is tampering with your connection.**


Don't add an exception unless you know there's a good reason why this site doesn't use trusted identification.



3. Kliknite "I Understand Risk" i "Add Exception...". Otvara se:
4. Kliknite "Confirm Security Exception"



Add Security Exception

 You are about to override how Firefox identifies this site.
Legitimate banks, stores, and other public sites will not ask you to do this.

Server

Location:

Certificate Status

This site attempts to identify itself with invalid information.

Wrong Site

The certificate belongs to a different site, which could mean that someone is trying to impersonate this site.

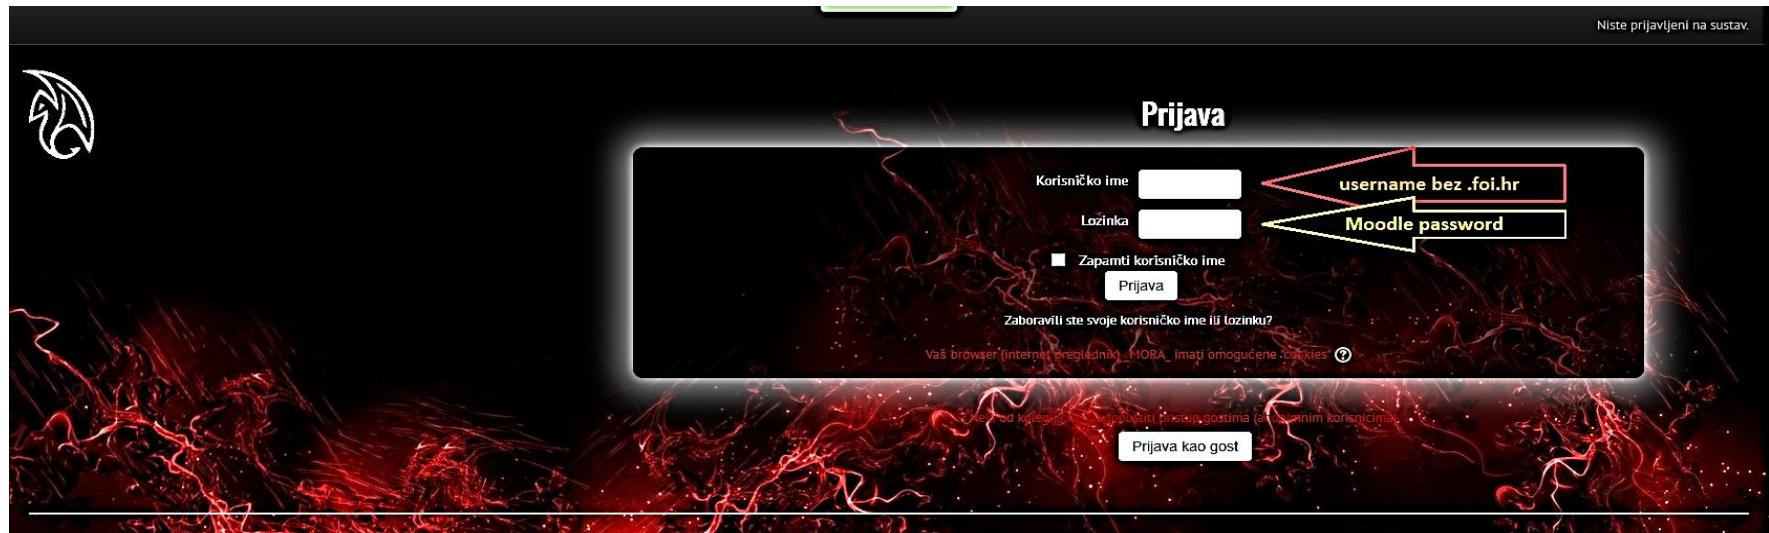
Unknown Identity

The certificate is not trusted because it hasn't been verified as issued by a trusted authority using a secure signature.

Permanently store this exception

Slika C. Primjer uputa za *eksperimentalnu* grupu ispitanika za *prvo glavno istraživanje* - 1. dio

5. Otvara se prijava u GMoodle sustav:



6. Prijavite se sa svojim @AAI računom
Korisničko ime je bez @foi.hr
Vaša lozinka od Moodle

7. Odaberite kolegij: **Programiranje 2**
Lozinka za kolegij: **lozinka GG**

8. Pročitajte upute unutar sustava, radite u tajnosti i zabavite se... :-)



Slika D. Primjer uputa za eksperimentalnu grupu ispitanika za *prvo glavno istraživanje* - 2. dio

<p>Primjer predtesta u predistraživanju</p> <ol style="list-style-type: none"> 1. X, Y, Z koordinatne osi označene su kao? X: X-axis, Y: Y-axis, Z: Z-axis. X-axis, Y-axis, Z-axis. X-axis, Y-axis, Z-axis. Ništa od navedenog. 2. Što je pivot u 3D modeliranju? centar modela. težište modela. rubna točka modela. prostorna pozicija modela. ništa od navedenog. 3. Koji pojam pripada alatima za modeliranje? Interactive split tool. Add divisions. Extrude. Bevel. sve od navedenog. 4. Koji pojam pripada alatima za manipulaciju poligonima? Combine. Smooth. Merge. Fill Hole. sve od navedenog. 5. Što je poligon? geometrijski objekt s minimalno četiri rubne točke. geometrijski objekt prikazan u minimalno tri dimenzije. geometrijski objekt s minimalno tri rubne točke. geometrijski objekt prikazan u minimalno dvije dimenzije. 6. Što prikazuje Maya Outliner? količinu modela u projektu. količinu poligona u projektu. količinu elemenata u projektu. količinu tekstura u projektu. ništa od navedenog. <ol style="list-style-type: none"> 7. Alat koji ima istovremenu mogućnost pomicanja, rotiranja i skaliranja modela je? Create Polygon tool. Insert Edge Loop tool. Extrude tool. Fill hole tool. Sve od navedenog. 8. Alat koji samostalno generira rubove oko modela ovisno o postojećoj geometriji je? Create Polygon tool. Insert Edge Loop tool. Separate tool. Fill hole tool. Sve od navedenog. 9. Postupak prelaska 3d modela u 2d sliku je? slikanje. konvertiranje. printanje. iscrtavanje. ništa od navedenog. 10. Ponavljanje zadnje manipulacije moguće je pomoću? kombinacije tipki CTRL + d. kombinacije tipki CTRL + g. kombinacije tipki SHIFT + d. kombinacije tipki SHIFT + g. Sve od navedenog. 11. Koji pojam ne pripada radu s Maya kamerom? Depth of Field Near Clip Angle Far Clip Plane Angle of View Aspect Ratio 12. Slobodno postavljane težišta modela moguće je korištenjem tipke? Delete. Home. Space. Insert. Ništa od navedenog. 	<p>Koji dio računalnog hardware-a (uz monitor) je odgovoran za ispravan prikaz i rad na 3d sceni?</p> <p>Koji dio računalnog hardware-a je zadužen za proces renderiranja?</p> <p>Objasnite važnost i primjenu ortogonalnih kamera (Top, Front, Side)?</p> <p>Koji elementi poligona (Vertex, Edge, Face) smatrate najvažnijim prilikom modeliranja i zašto?</p> <p>Objasnite mogućnosti povezivanja Maya sa srodnim programima (Cinema 4D, Blender, 3ds Max)?</p> <p>Objasnite važnost teksture i materijala za sjenčanje.</p>
--	---

Slika E. Primjer predtesta kreiranog za predistraživanje

<p>Ime i prezime: _____, M / Ž</p> <p>Redovni / Iznaredni</p> <p>1. X, Y, Z koordinatne osi označene su kao? X-axis, Y-axis, Z-axis. X-axis, Y-axis, Z-axis. X-axis, Y-axis, Z-axis. Ništa od navedenog.</p> <p>2. Što je Mental ray? Sustav za teksturiranje 3D modela. Sustav za renderiranje 3D modela. Sustav za povezivanje 3D modela. Sustav za modeliranje 3D modela. Ništa od navedenog.</p> <p>3. Što predstavlja pojam Cast Shadow? Povezivanje 3D modela i izvora svjetla. Najpoznatiji tip sjena u Mental rayu. Refleksiju svjetla i sjene u Mental rayu. Refleksiju svjetla i sjene u Mental rayu. Ništa od navedenog.</p> <p>4. Što predstavlja pojam Ambient Occlusion? Direktan sustav refleksija sjena. Indirektan sustav refleksija sjena. Generiranje sjene u 3D sceni. Generiranje svjetla u 3D sceni. Ništa od navedenog.</p> <p>5. Što su Depth Map sjene? Sjene koje se unaprijed definirane scenom. Sjene koje se najduže generiraju za prikaz. Sjene koje se najbrže generiraju za prikaz. Sjene koje su ovisne o položaju kamere. Ništa od navedenog.</p> <p>6. Detail Map sjene su: Podvrsta Raytrace Map sjena. Podvrsta Ambient Map sjena. Podvrsta Depth Map sjena. Podvrsta Sun Map sjena. Ništa od navedenog.</p> <p>7. Ray Trace sjena je? Najbrži sustav generiranja sjena. Unaprijed definiran sustav sjena. Najprecizniji sustav sjena. Najjednostavniji sustav sjena. Ništa od navedenog.</p> <p>8. Što je Globalna Iluminacija? Direktno teksturiranje kroz Metal ray. Indirektno teksturiranje kroz Metal ray. Apsorpcija ili refleksija zrake svjetla. Globalne postavke za renderiranje scene. Ništa od navedenog.</p> <p>9. Postupak prelaska 3d modela u 2d sliku je? slikanje. konvertiranje. printanje. iscrtavanje. rendering. ništa od navedenog.</p> <p>10. Što su Foton mape? Čestice sjene u Mental ray sustavu. Čestice svjetla u Mental ray sustavu. Čestice refleksije u Mental ray sustavu. Čestice refrakcije u Mental ray sustavu. Ništa od navedenog.</p> <p>11. Što predstavlja pojam Irradiance u Mayi? Zasićenost u globalnom teksturiranju. Zasićenost u globalnom osvjetljenju. Zasićenost u globalnom modeliranju. Zasićenost u globalnom animiranju. Ništa od navedenog.</p> <p>12. Što predstavlja pojam Caustics u Mayi? Simulaciju svjetla u globalnoj iluminaciji. Simulaciju svjetla prilikom renderiranja. Simulaciju svjetla prilikom refleksije. Simulaciju svjetla prilikom refrakcije. Sve od navedenog.</p> <p>13. Što predstavlja pojam Depth of Field? zamućenost svjetla. zamućenost pogleda. zamućenost kretnje. zamućenost sjene. ništa od navedenog.</p>	<p>14. Što predstavlja pojam Final Gathering? Metodu za računanje direktnih sjena. Metodu za računanje indirektnih svjetlosti. Metodu za računanje indirektnih svjetlosti. Metodu za računanje X-ray svjetlosti. Ništa od navedenog.</p> <p>15. Koje je svojstvo Final Gathering mape? Ubrzava proces računanja transparentcije. Ubrzava proces računanja refrakcije. Ubrzava proces računanja refleksije. Ubrzava proces računanja renderiranja. Sve od navedenog.</p> <p>16. Što su Light Emitting objekti? Objekti koji isijavaju svjetlost. Objekti koji služe kao direktno svjetlo. Objekti koji služe kao indirektno svjetlo. Objekti koji su dio modelirane scene. Sve od navedenog.</p> <p>17. Što predstavlja pojam Image Based Lighting? Sustav osvjetljenja pomoću 3d fotografije. Sustav osvjetljenja pomoću 2d fotografije. Sustav osvjetljenja pomoću krivulja. Sustav osvjetljenja pomoću vektora. Sve od navedenog.</p> <p>18. Physical Sun and Sky se nalazi unutar: Maya vektora sustava za renderiranje. Maya software sustava za renderiranje. Mental ray sustava za renderiranje. V ray sustava za renderiranje. Svega od navedeno.</p> <p>19. Koji pojam ne pripada Maya svjetlima? Ambient light. Spot light. Volume light. Raytracing light. Directional light. Sve od navedeno.</p> <p>20. Koji pojam pripada Maya sjenama? Area shadows. Depth Map shadows. Reflection shadows. Indirect shadows. ništa od navedenog.</p> <p>21. Što su Mia materijali? Materijali Maya Software-a. Materijali Maya Hardware-a. Materijali Maya Vector-a. Materijali Mental ray-a. Ništa od navedenog.</p> <p>22. Transparentnost je osobina kojeg sjencanja? Lambert sjencanja. Phong sjencanja. Phong G sjencanja. Blinn sjencanja. Sve od navedenog.</p> <p>23. Što predstavlja pojam Hypershade Sustav za uređenje 3d modela. Sustav za uređenje shadera. Sustav za uređenje poligona. Sustav za uređenje verteksa. ništa od navedenog.</p> <p>24. Što pripada sustavu za renderiranje? Maya software. Maya hardware. Mental ray. V ray. sve od navedenog.</p> <p>25. Što od navedenog utječe na finalnu kvalitetu slike? Broj poligona u sceni. Broj tekstura u sceni. Broj sličica u sekundi. Broj kamera u sceni. ništa od navedenog.</p> <p>26. Koji format Maya ne može pohraniti? .mib .obj .fbx .3ds .ma</p>
<p>1</p>	<p>2</p>

Kreirani je s ciljem poboljšanja trenutačnih sustava za isušivanje.
Vaše podatke ostaju anonimni i neće se koristiti u bilo koju drugu svrhu.

Uputnik se koristi u znanstveno-distraživnom radu.

Slika F. Primjer posttesta kreiranog za predistraživanje

FOI – provjera znanja – Predtest

Ime i prezime: _____

Redovni / Ivanredni, Mat.broj: _____

1. 32 bitni INT omogućuje raspon vrijednosti:
 - 0 do 65535
 - 32768 do 32767
 - 2.1*10⁸ do 2.1*10⁸
 - 9.2*10³⁷ do 9.2*10³⁷
2. Nije ključna riječ jezika C++:
 - const
 - static
 - object
 - void
3. Što se ispisuje? int a=5; cout << a++;
 - 4
 - 5
 - 6
4. Naredba break omogućuje izlaz iz:
 - programa
 - potprograma
 - kontrolne strukture
 - selekcije tipa if
5. Što se ispisuje? int a=0x12; cout << a;
 - 12
 - 18
 - 0x12
 - 16
6. Što se ispisuje? int a=66; cout << (char)a;
 - 66
 - A
 - a
 - B
7. Karakteristika strukturnog programiranja je
 - izbacivanje:
 - for naredbe
 - goto naredbe
 - continue naredbe
 - break naredbe

FOI – provjera znanja – Pred test

Objasnite jednostavne i složene tipove podataka.

Što je varijabla i koja su njena svojstva.

Razradite postupak uzlaznog Bubblesort na primjeru brojeva 4, 2, 1, 3.

Objasnite selekciju tipa "if" i njena varijante.

Objasnite pojam polja u programiranju i navedite vrste.

FOI – provjera znanja – Predtest

8. Što se ispisuje?


```
enum dan {ucer, danas, sutra};
dan dj dan = sutra; cout << dan;
```

 - sutra
 - danas
 - 1
 - 2
9. Što se ispisuje? cout << (2==2);
 - 0
 - 1
 - 2
10. Što od navedenog nije logički operator u C++?
 - &&
 - ||
 - !
 - !
11. Što nije preddefinirani tip u C++?
 - short int
 - longdouble
 - char
 - byte
12. Nisu jednostavni tipovi u C++:
 - znakovi
 - cijeli brojevi
 - znakovni nizovi
 - realni brojevi
13. Odaberite cjelobrojni tip podataka.
 - longdouble
 - longint
 - longfloat
 - long char
14. Koji od primjera definira statičko polje od pet elemenata tipa float?
 - float a,b,c,d,e;
 - float a[5];
 - float b[5];
 - float a = new float[5];

FOI – provjera znanja – Pred test

Objasnite jednostavne i složene tipove podataka.

Što je varijabla i koja su njena svojstva.

Razradite postupak uzlaznog Bubblesort na primjeru brojeva 4, 2, 1, 3.

Objasnite selekciju tipa "if" i njena varijante.

Objasnite pojam polja u programiranju i navedite vrste.

Upitnik se koristi u znanstveno-istraživačkom radu.
Kreiran je s ciljem poboljšanja trenutnih sustava za evaluiranje.
Vaši podaci ostaju anonimni i neće se koristiti u bilo koju drugu svrhu.

Slika G. Primjer *predtesta* kreiranog za *prvo glavno istraživanje*

FOI – provjera znanja – Posttest

Ime i prezime: _____

Redovni / Iznanredni, Mat.broji: _____

1. Prednost Heep sorta u odnosu na Quicksort je može se implementirati uz pomoć polja
brže sortiranje
može se implementirati uz pomoć rekurzije
može se implementirati uz pomoć stoga
2. Glava koje strukture nije istog tipa kao ostali elementi:
vezane liste
stoga
reda čekanja
binarnog stabla
3. Indeks podređenog čvora za čvor i u hrpi izračunava se po formuli:
podređeni $= i * 2 + 1$
podređeni $= i * 2 - 1$
podređeni $= (i-1) / 2$
podređeni $= (i-1) * 2$
4. Kojom operacijom se stavlja vrijednost na vrh stoga:
push
pull
pop
insert
5. Kraj stoga zadaje se kojom vrijednošću pokazivača u zadnjem elementu:
adresa glave reda
0
adresa prvog elementa
adresa zadnjeg elementa
6. Sve operacije nad stogom izvršavaju se:
na vrhu stoga
na dnu stoga
nad svim elementima stoga
u sredini stoga
7. Što predstavlja vrijednost NULL pokazivača stoga:
da nema stoga
da je stog prazan
da je stog pun
da nije moguća alokacija stoga

FOI – provjera znanja – Post test

Ispravite pogrešku u kodu:

```
struct cvor{
int broj;
telemnt *slijedeci;
};
cvor *vrh = NULL;
```

Ispravite pogrešku u kodu:

```
fstream dat;
dat.open("tekst.txt",ios::in);
dat << "Prvi red teksta\n";
dat << "Drugi red teksta" << endl;
dat.close();
```

Ispravite pogrešku u kodu:

```
void zamjena (int &a, int &b){
int t = a;
a = b;
b = t;
}
void main(){
zamjena (3,5);
cout << x << y << endl; }
```

Što će se ispisati?

```
int *pok;
pok = new int;
*pok = 10;
cout << (bool) pok << endl;
```

Što će se ispisati?

```
void funkcija(int a, int b=5){
cout << "a " << a << endl;
cout << "b " << b << endl;
}
void main(){
funkcija (3,4);
funkcija (5); }
```

8. Glava reda čekanja deklarirana je ovako:
struct tglava {telemnt *pocetak, *kraj};
Koja instrukcija ispisuje veličinu pojedinog elementa reda (u bajtima)?
cout << sizeof (tglava);
cout << sizeof (pocetak);
cout << sizeof (*tglava);
cout << sizeof (telemnt);

9. Svaki objekt koji se dinamički alocira smješta se na:
stog
hrpu
vezanu listu
red čekanja

10. Hrpa po svojoj strukturi predstavlja:
poseban oblik binarnog stabla
poseban oblik stoga
oblik rekurzije
oblik nasljedivanja

11. Osnovna karakteristika hrpe je da je nadređeni čvor:
manji ili jednak oba podređena
manji od jednog podređenog
uvijek veći od oba podređena

12. Dealokacija stoga provodi se :
uzastopnim brisanjem vrha stoga
uzastopnim brisanjem dna stoga
brisanjem pokazivača stoga
uzastopnim izvršavanjem operacije *Push*

13. Što ne vrijedi za statičke lokalne varijable?
imaju trajanje globalnih varijabli
alociraju se na stogu
imaju doseg lokalne varijable
alociraju se na hrpi

14. Koji od primjera definiira statičko polje od 5 elemenata tipa *char* :
char a,b,c,d,e;
char a[5];
char b[5];
char a = new char[5];

1

Upitnik se koristi u znanstveno-istraživačkom radu.

Kreiran je s ciljem poboljšanja trenutnih uvjeta za evaluiranje. Vaša pomoć ostaje anonimna i neće se koristiti u bilo kojoj drugu svrhu.

2

Ime i prezime: _____, M / Z

Redovni / Izvanredni

- Čovjek zapamti:
 - 30% onoga što čuje.
 - 10% onoga što pročita.
 - 50% onoga što vidi i čuje.
 - 30% onoga što vidi.
 - 70% onoga što vidi, čuje i uradi.
- Koji su osnovni elementi multimedija?
 - Grafika.
 - Tekst.
 - Zvuk.
 - Animacija.
 - Svi od navedenih.
- Hipermedija nastaje kada se hipertekstu dodaje:
 - Grafika.
 - Animacija.
 - Zvuk.
 - Video.
 - Sve od navedenog.
- Računalna grafika može biti?
 - Točkasta.
 - Linijaska.
 - Kružna.
 - Vektorska.
 - Sve od navedenog.
- Grafički formati slika mogu biti:
 - Namijenjeni za bitmapiranu grafiku.
 - Namijenjeni za vektorsku grafiku.
 - Zavisni i ne zavisni od platforme.
 - Sa ili bez kompresije.
 - Sve od navedenog.
- Koji od navedenih tipova datoteka ne pripada u grafičke formate slika?
 - .TIFF
 - .PNG
 - .EPS
 - .MOV
 - .PSD

- Koji format se ne koristi za grafiku na webu?
 - .GIF
 - .PNG
 - .TIFF
 - .RAW
 - Sve od navedenog.
- Sa 8 bita možemo prikazati?
 - 64 boja.
 - 128 boja.
 - 256 boja.
 - 512 boja.
 - Ništa od navedenog.
- Sustav osnovnih boja kod monitora i TV-a je:
 - CMYK sustav boja.
 - RGB sustav boja.
 - RT HD sustav boja.
 - SW HD sustav boja.
 - Ništa od navedenog.
- CMYK sustav boja se dobiva miješanjem:
 - RT HD + posebno crnom (K) bojom.
 - RGB + posebno crnom (K) bojom.
 - CMY + posebno crnom (K) bojom.
 - SW HD + posebno crnom (K) bojom.
 - Ništa od navedenog.
- Dubina boje (Color depth) se definira kao?
 - Broj piksela kojim se boja opisuje.
 - Broj vektora kojim se boja opisuje.
 - Broj rastera kojim se boja opisuje.
 - Broj bitova kojim se boja opisuje.
 - Ništa od navedenog.
- Dio centralne procesne jedinice nije:
 - Aritmetička jedinica.
 - Upravljačka jedinica.
 - Logička jedinica.
 - Sabirnica.
 - Registri.
- Sustavska programska podrška može biti
 - Operacijski sustav.
 - Pogonski programi (eng. Driver).
 - Program prevoditelj.
 - Servisni programi (eng. Tools)
 - Sve od navedenog.

1

2

Slika I. Primjer *predtesta* kreiranog za *drugu glavno istraživanje*

Ime i prezime: _____, M / Ž

Redovni / Izvanredni

1. Bitmapa može biti:
Crno-Bijela (monokromatska) slika.
Slika u tonovima sive boje.
Slika u 8-bitnoj boji.
Slika u 24-bitnoj boji.
Sve od navedenog.
2. Semiotika je znanost o:
Grafičkim sustavima.
Vizualnim sustavima.
Adaptivnim sustavima.
Znakovnim sustavima.
Sve od navedenog.
3. Računalna grafika ne može biti?
Trodimenzionalna.
Dvodimenzionalna.
Rasterska
Linjska.
Vektorska.
4. Koji je osnovni element multimedije?
Grafika.
Tekst.
Zvuk.
Animacija.
Sve od navedenog.
5. Uređaj za izradu multimedijskih sadržaja može biti:
Digitalan fotoaparati.
Video kamera.
Diktafon.
Skener.
Sve od navedenog.
6. Koji od navedenih tipova datoteka ne pripada u grafičke formate slike?
.TIFF
.AVI
.PNG
.EPS
.PSD
7. Codec je program za:
Analizu audio i video sadržaja.
Pokretanje audio i video sadržaja.
Fragmentaciju audio i video sadržaja.
Dekompresiju audio i video sadržaja.
Sve od navedenog.
8. Koji od navedenih formata koristi kompresiju?
.VCD
.XVID
.DVD
.DIVX
Svi od navedenih.
9. Koji se od navedenih programa ne koristi za izradu multimedije?
Windows Media Player
Winamp.
DVD player.
ACD See.
MediaFire.
10. CMYK sustav boja se obično miješanjem:
RT HD + posebno crnom (K) bojom.
RGB + posebno crnom (K) bojom.
CMY + posebno crnom (K) bojom.
SW HD + posebno crnom (K) bojom.
Ništa od navedenog.
11. Koja tehnologija od navedenih je namijenjena animaciji?
GIF
Java
Flash
Shockwave
Sve od navedenog.
12. Što od navedenog nije dio 3D računalne grafike?
Sjenčanje.
Tekstuiranje.
Renderiranje.
Vektoriranje.
Modeliranje.

1

Objasnite povezanost između vizualne komunikacije i grafičkog dizajna.

Objasnite pojam i ključne elemente digitalne kompetencije.

Objasnite koje su povezanosti između Web 2.0 alata i multimedije.

Koja su osnovna načela multimedijskog oblikovanja sadržaja za web ili kompaktnu ploču (CD).

Objasnite važnost i značenje dizajniranja korisničkog sučelja za multimedijske potrebe.

Objasnite povezanost multimedije i suvremene komunikacije.

2

Kreiranje je s kojim poboljšanje trenutnih sustava za učenje.
Vidjeti također: [anotirati / neke se koriste u Bilo koju drugu svrhu](#)

Upitnik se koristi u znanstveno-istraživačkom radu.

PRILOG 3. ANKETNI UPITNIK MOTIVACIJE I ZADOVOLJSTVA IZ PREDISTRAŽIVANJA

ISTRAŽIVANJE UVJETA E-UČENJA

ANKETNI UPITNIK – 2015

Uputa

Prezime i ime:

Ovaj upitnik je dobrovoljan. Nakon što ga popunite i predate anketaru, smatramo da ste suglasni s korištenjem vaših odgovora za potrebe znanstvenog istraživanja i statističke obrade podataka. Predviđeno vrijeme za popunjavanje upitnika je oko 20-25 minuta, a pitanja su uglavnom koncipirana tako da treba označiti u kojoj mjeri se na Vas odnose pojedine tvrdnje.

MOLIMO DA ZAOKRUŽIVANJEM ODGOVORITE NA SLJEDEĆE TVRDNJE.

Dob: a) 18 g. b) 19 g. c) 20 g. d) 21 g. e) 22 g. f) 23 i više g.

Spol: a) muško b) žensko

KOLIKO DUGO KORISTITE SLJEDEĆE RAČUNALNE, INTERNETSKJE I DRUGE TEHNOLOGIJE:

Računalo kod kuće: ne koristim do godinu dana 2-3 godine 4-5 godina 6-10 godina više od 10 godina

Internet kod kuće: ne koristim do godinu dana 2-3 godine 4-5 godina 6-10 godina više od 10 godina

KOLIKO MNOGO (U PROSJEKU) KORISTITE SLJEDEĆE TEHNOLOGIJE KOD KUĆE I NA FAKULTETU:

Računalo kod kuće: nekoliko puta tjedno manje od 1 sata svakodnev. 1-2 sata dnev. 3-5 sata dnev. 6 i više sati dnev.

Računalo na fakult.: nekoliko puta tjedno manje od 1 sata svakodnev. 1-2 sata dnev. 3-5 sata dnev. 6 i više sati dnev.

Internet kod kuće: nekoliko puta tjedno manje od 1 sata svakodnev. 1-2 sata dnev. 3-5 sata dnev. 6 i više sati dnev.

Internet na fakult.: nekoliko puta tjedno manje od 1 sata svakodnev. 1-2 sata dnev. 3-5 sata dnev. 6 i više sati dnev.

KOLIKO DUGO KORISTITE SLJEDEĆE TEHNOLOGIJE:

E-mail: ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

Forum: ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

Videokonferencije i webinare: ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

Web 2.0 (npr. wiki, blog): ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

Facebook i društvene mreže: ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

Neki sustav za e-učenje (npr. Moodle ili drugi):

ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

KOLIKO MNOGO (U PROSJEKU) KORISTITE TEHNOLOGIJE E-UČENJA (Moodle ili sl.):

Kod kuće: nekoliko puta tjedno manje od 1 sata svakodnev. 1-2 sata dnev. 3-5 sata dnev. 6 i više sati dnev.

Na fakult.: nekoliko puta tjedno manje od 1 sata svakodnev. 1-2 sata dnev. 3-5 sata dnev. 6 i više sati dnev.

Slika K. Primjer *anketnog upitnika* kreiranog za *predistraživanje* - 1. dio

KOLIKO DUGO KORISTITE SLJEDEĆE RESURSE ZA PRISTUP INTERNETU?

Mobilni Internet (npr. Vipnet stick): ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina
Internet sa širokopojasnom vezom: ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina
Bežične lokalne mreže (WLAN): ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

Zadovoljstvo

(Q1) Uživao/la sam u korištenju e-tečaja.	1	2	3	4	5
(Q43) Estetske karakteristike e-tečaja nisu bile impresivne.	1	2	3	4	5
(Q47) Htio sam istražiti sadržaje i mogućnosti e-tečaja.	1	2	3	4	5
(Q45) E-tečaj me nije uspio motivirati da ga nastavim koristiti.	1	2	3	4	5
(Q5) E-tečaj mi se učinio zabavnim.	1	2	3	4	5
(Q11) Rad se e-tečajem me je obradovao.	1	2	3	4	5
(Q6) Bilo mi je dosadno koristiti e-tečaj.	1	2	3	4	5
(Q21) Izgled e-tečaja meni je bio zanimljiv.	1	2	3	4	5
(Q39) Prema mojoj procjeni, osnovna nit vodilja (smisao) tečaja prilično je dosadna.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Pregled nad tečajem / navigacija

(Q18) Imao sam dobar pregled nad svim dijelovima e-tečaja.	1	2	3	4	5
(Q29) Uvijek sam znao(la) kako da ostvarim svoj cilj u e-tečaju.	1	2	3	4	5
(14) Izbornici (meniji) i drugi alati za upravljanje e-tečajem bili su vrlo upotrebljivi.	1	2	3	4	5
(Q25) Mislim da su načini upravljanja tečajem bili lako razumljivi (intuitivni).	1	2	3	4	5
(GB1) Imao(la) sam probleme sa snalaženjem u tečaju / kretanjem kroz tečaj.	1	2	3	4	5
(27) Znao(la) sam kako će moje akcije unutar e-tečaja (npr. korištenje izbornika) djelovati na aktiviranje pojedinih funkcionalnosti samog tečaja.	1	2	3	4	5
(28) Uvijek sam znao kako postići ono što želim koristeći izbornik i druge opcije unutar e-tečaja.	1	2	3	4	5
(15) Uvijek sam znao(la) kako se kretati unutar e-tečaja.	1	2	3	4	5
(37) Nisam se uvijek mogao(la) snaći s izbornikom (menijem) i poveznicama (linkovima) unutar e-tečaja.	1	2	3	4	5
(Q27) Nisam znao(la) kako će e-tečaj reagirati na moje akcije.	1	2	3	4	5
(Q28) „Mehanički“ aspekti (procedure rada) u e-tečaju bili su konzistentni.	1	2	3	4	5
(Q44) Sustav e-tečaja omogućavao je dobar pregled svih sadržaja i aktivnosti u tečaju.	1	2	3	4	5
(Q30) Događalo se da se izgubim (izgubim „orijentaciju“) koristeći mogućnosti e-tečaja.	1	2	3	4	5
(Q37) Nisam mogao „pronaći svoj put“ u e-tečaju.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Feedback (GB)

(F1) Dobivao(la) sam dovoljno povratnih informacija o svojim rezultatima prilikom rada sa e-tečajem.	1	2	3	4	5
(F2) Kod svake, pa i najmanje aktivnosti u e-tečaju dobivao/dobivala sam povratnu informaciju o mojem učinku/uspjehu.	1	2	3	4	5
(F3) Dobivao(la) sam informaciju o svojem statusu tijekom rada s e-tečajem (npr. rezultatu u nekoj aktivnosti u odnosu na druge).	1	2	3	4	5
(Kov23) Povratne informacije tijekom rada s e-tečajem dobivao(la) sam odmah ili vrlo brzo po završetku aktivnosti.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Slika L. Primjer *anketnog upitnika* kreiranog za *predistraživanje* - 2. dio

Zaokupljenost /uživljavanje

(Q13) Uspio/uspjela sam se jako uživjeti u e-tečaj.	1	2	3	4	5
(Q20) Nisam gubio(la) osjećaj za vrijeme tijekom rada sa e-tečajem.	1	2	3	4	5
(C1) E-tečaj je jako privlačio moju pozornost.	1	2	3	4	5
(3) Bio/bila sam usredotočen(a) na zadatke u e-tečaju.	1	2	3	4	5
(Q41) Dok sam koristio(la) e-tečaj, razmišljao(la) sam o stvarima koje <u>nisu</u> povezane sa e-tečajem.	1	2	3	4	5
(Q4) Mogao(la) sam se poistovjetiti s drugim korisnicima e-tečaja.	1	2	3	4	5
(C6) Tijekom rada s e-tečajem <u>nije</u> bilo moguće skrenuti moju pozornost sa zadataka u tečaju.	1	2	3	4	5
(Q23) Učinilo mi se kao da sam zaboravio na to gdje se nalazim prilikom korištenja e-tečaja.	1	2	3	4	5
(Q3) Spontano sam se fokusirao/fokusirala na e-tečaj.	1	2	3	4	5
(C2) Sadržaj e-tečaja povećavao je moju usredotočenost.	1	2	3	4	5
(20) Nisam imao(la) osjećaj kako vrijeme brzo prolazi dok sam radio(la) s e-tečajem.	1	2	3	4	5
(4) Nisam mogao(la) zblížiti se s drugim sudionicima e-tečaja.	1	2	3	4	5
(23) Znalo mi se dogoditi da zaboravim na protok vremena prilikom korištenja e-tečaja.	1	2	3	4	5
(16) Emocionalno sam se jako aktivirao(la) prilikom rada s e-tečajem.	1	2	3	4	5
(41) Prilikom rada s e-tečajem moje misli su znale odlutati na druge teme ili sam započinjao(la) druge aktivnosti koje nisu bile vezane uz e-tečaj.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Priprema / uputa za rad s e-tečajem (GB)

(8) E-tečaj je imao uputu za upoznavanje s načinom rada u tečaju.	1	2	3	4	5
(GB1) Uputa za rad s izbornicima (menijima) i drugim funkcionalnostima bila je jasna i dovoljno detaljna.	1	2	3	4	5
(16) U e-tečaju je bilo dobro objašnjeno kako treba prilagoditi postavke e-tečaja (profil korisnika, pretplatu na forume i sl.).	1	2	3	4	5
(24) Stranica („ekran“) e-tečaja s opcijama za podešavanje bila mi je nedovoljno razumljiva.	1	2	3	4	5
(36) Izbornici (meniji) e-tečaja bili su teški za svladavanje i korištenje.	1	2	3	4	5
(37) Zbog loše upute nisam se uvijek mogao(la) snaći s izbornikom (menijem) i poveznicama (linkovima) unutar e-tečaja.	1	2	3	4	5
(Q19) E-tečaj mi je omogućio korištenje pomoćnih informacija („help“) u pravim trenucima.	1	2	3	4	5
(G1) Opći ciljevi e-tečaja dobro su predstavljeni na njegovom početku.	1	2	3	4	5
(G4) Ciljevi za pojedine faze rada s e-tečajem bili su jasni i dovoljno često istaknuti.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Primjerena težina e-tečaja (GB)

(Q10) E-tečaj mi je bio lagan za svladati.	1	2	3	4	5
(Q48) Težina tečaja za mene je bila primjerena.	1	2	3	4	5
(GB2) Dijelovi e-tečaja za mene su bili preteški.	1	2	3	4	5
(48) Težina e-tečaja nije bila prihvatljiva u odnosu na moje sposobnosti.	1	2	3	4	5
(GB3) Gradivo e-tečaja <u>nije</u> bilo presloženo za razumjeti.	1	2	3	4	5
(GB4) Kad bih imao(la) dovoljno vremena, svi sadržaji tečaja bili bi mi lagani za svladati.	1	2	3	4	5
(Q22) Kontrolne funkcije za korištenje e-tečaja bile su mi prekomplcirane.	1	2	3	4	5
(C8) Količina opterećenja za svladavanje e-tečaja bila je primjerena.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Slika M. Primjer *anketnog upitnika* kreiranog za *predistraživanje* - 3. dio

Razni motivacijski poticaji

(38) Načini motiviranja studenata na svladavanje e-tečaja bili su dovoljno različiti.	1	2	3	4	5
(41) Prilikom rada s e-tečajem bio/bila sam ravnodušan/ravnodušna prema načinima poticanja (bodovanje, rangiranje i sl.) na veće zalaganje u e-tečaju.	1	2	3	4	5
(Q38) Mogućnosti e-tečaja učinile su mi se dovoljno izazovnim (poticajnim).	1	2	3	4	5
(P1) E-tečaj posjeduje jasnu i organiziranu strukturu nastavnog materijala.	1	2	3	4	5
(P2) E-tečaj sam dobro iskoristio.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Molimo da procijeniti koliko su Vas sljedeći elementi potaknuli da s više zalaganja i motiva svladavate sadržaje e-tečaja. Prilikom procjene koristite sljedeću skalu u rasponu od 1 – 7:

1-nimalo 2- vrlo malo 3-malo / ispodprosječno 4-prosječno / umjereno 5-podosta / iznadprosječno 6-mnogo 7- vrlo mnogo

Edukacijske igre	1	2	3	4	5	6	7
Multimedijalni elementi	1	2	3	4	5	6	7
Blog	1	2	3	4	5	6	7
Forum	1	2	3	4	5	6	7
Upitnici	1	2	3	4	5	6	7
Chat	1	2	3	4	5	6	7
Uređivanje profilne slike i osobnih informacija	1	2	3	4	5	6	7
Bonus nastavni materijali	1	2	3	4	5	6	7
Motivirajući smisao / Priča	1	2	3	4	5	6	7
Vizualan status studentskih obveza	1	2	3	4	5	6	7
Vizualan status studentskog napretka	1	2	3	4	5	6	7
Vizualan status završenosti kolegija	1	2	3	4	5	6	7
Nivo težine (eng. level)	1	2	3	4	5	6	7
Trenutno ostvareni bodovi za završene aktivnosti	1	2	3	4	5	6	7
Top lista najboljih studenata	1	2	3	4	5	6	7
Bedževi za postignuća	1	2	3	4	5	6	7
Bodovi za postignuća	1	2	3	4	5	6	7
Certifikati za postignuća	1	2	3	4	5	6	7

Interakcija

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

(S1) Osjećao(la) sam se povezano s drugim korisnicima e-tečaja.	1	2	3	4	5
(S2) Vrlo dobro sam surađivao s drugim korisnicima e-tečaja.	1	2	3	4	5
(S3) Suradnja s drugim korisnicima e-tečaja bila mi je korisna u učenju.	1	2	3	4	5
(S4) E-tečaj je dobro podržavao socijalnu interakciju između korisnika (npr. chat, forum).	1	2	3	4	5
(S5) E-tečaj je primjeren podržavao komunikaciju među korisnicima unutar samog sustava vezanu uz učenje gradiva.	1	2	3	4	5
(P9) Bilo je moguće jednostavno i brzo prenositi informacije i znanja između studenata / korisnika e-tečaja.	1	2	3	4	5
(P10) Mogao(la) sam koristiti mnogo različitih komunikacijskih alata za razmjenu informacija s drugim studentima	1	2	3	4	5
(P11) E-tečaj je omogućavao kooperativno učenje i grupni rad s ostalim korisnicima sustava.	1	2	3	4	5
(P12) E-tečaj mi je omogućavao osobno stupanje u kontakt s pojedinim studentima.	1	2	3	4	5
(Q40) E-tečaj sam koristio prema svojim pravilima, neovisno o drugim sudionicima tečaja.	1	2	3	4	5
(Q42) Moj položaj i ovlasti u tečaju nisu mi omogućavali uvid u to što rade i postižu drugi korisnici e-tečaja.	1	2	3	4	5

Slika N. Primjer *anketnog upitnika* kreiranog za *predistraživanje* - 4. dio

Postignuće učenja

(K1) Korištenje e-tečaja je povećalo moje znanje.	1	2	3	4	5
(K2) Savladao(la) sam osnovne ideje vezane uz traženo znanje u sklopu e-tečaja.	1	2	3	4	5
(K3) Pokušao(la) sam vlastito znanje što više primijeniti u e-tečaju.	1	2	3	4	5
(K4) E-tečaj je motivirao korisnike za povezivanje naučenog znanja.	1	2	3	4	5
(K5) Htio/htjela sam što više znati više o predmetu/znanju koje se poučavalo e-tečajem.	1	2	3	4	5
(P18) E-tečaj je dobro omogućavao stjecanje znanja i vještina o promatranoj temi.	1	2	3	4	5
(P19) E-tečaj je omogućavao stjecanje vještina za praktičnu primjenu znanja.	1	2	3	4	5
(P20) E-tečaj je omogućavao stjecanje vještina za komunikaciju i suradnju.	1	2	3	4	5
(48) Osjećao/osjećala sam da mogu nešto za mene korisno naučiti tijekom rada s e-tečajem.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Individualni proces učenja

(P13) E-tečaj mi je omogućavao slobodno korištenje resursa neovisno o vremenu i prostoru.	1	2	3	4	5
(P14) E-tečaj mi je omogućavao vlastiti odabir strategije i brzine učenja.	1	2	3	4	5
(P15) E-tečaj mi je omogućavao (samo)provjeru mogeg znanja na kraju svakog poglavlja i usporedbu s drugim studentima.	1	2	3	4	5
(P15) U e-tečaju sam mogao raditi onom brzinom/tempom kako sam htio i koliko mi je to odgovaralo.	1	2	3	4	5
(P16) E-tečaj mi je omogućavao kontroliranje ishoda/rezultata mogeg učenja.	1	2	3	4	5
(P16) Imao/la sam mogućnost provjeravati koliko sam naučio/la kad god sam to poželio/poželjela.	1	2	3	4	5
(P17) E-tečaj je vrlo dobro održavao moju motivaciju za učenjem.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Upitnik o doživljaju e-tečaja

(2) Bio/bila sam frustriran(a) na kraju e-tečaja.	1	2	3	4	5
(6) Osjećao(la) sam kontrolu prilikom korištenja e-tečaja.	1	2	3	4	5
(9) Mogao / mogla sam na ekranu vidjeti sve informacije koje su mi potrebne prilikom korištenja e-tečaja.	1	2	3	4	5
(10) Raspored nastavnih materijala unutar e-tečaja nije mi logički odgovarao.	1	2	3	4	5
(11) Znao(la) sam što sam u svakom trenutku što sam trebao/la raditi u e-tečaju.	1	2	3	4	5
(12) Bilo je trenutaka kada nisam ništa radio/la u e-tečaju.	1	2	3	4	5
(13) Sviđao mi se izgled e-tečaja.	1	2	3	4	5
(14) Grafičko sučelje e-tečaja bilo je pregledno.	1	2	3	4	5
(15) Mnoge stvari mi se nisu dopale u vezi e-tečaja.	1	2	3	4	5
(25) Mislim kako je kretanje kroz e-tečaj bilo lako shvatljivo.	1	2	3	4	5
(26) Grafičko sučelje e-tečaja bilo je prikladno ovakvom tipu sustava za učenje.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Slika O. Primjer *anketnog upitnika* kreiranog za *predistraživanje* - 5. dio

Upitnik za evaluaciju e-tečaja

	1 – potpuno netočno	2 – uglavnom netočno	3 – ni točno, ni netočno	4 – uglavnom točno	5 – potpuno točno
(IM2_1) Dok sam koristio e-tečaj razmišljao(la) sam kako sam uživao(la).	1	2	3	4	5
(IM2_2) Mislim kako sam imao mogućnost odabira koristiti e-tečaj.	1	2	3	4	5
(IM2_2) Nisam se osjećao(la) živčanim prilikom korištenja e-tečaja.	1	2	3	4	5
(IM2_3) Osjećao(la) sam kako je rad u e-tečaju moj odabir.	1	2	3	4	5
(IM2_4) Mislim kako sam poprilično dobar/dobra u savladavanju ovog e-tečaja.	1	2	3	4	5
(IM2_4) Mislim kako je korištenje ovog e-tečaja korisno za poboljšanje koncentracije.	1	2	3	4	5
(IM2_5) Mislim kako je e-tečaj vrlo zanimljiv.	1	2	3	4	5
(IM2_6) Povremeno sam se osjećao(la) nervozno prilikom korištenja e-tečaja.	1	2	3	4	5
(IM2_6) Mislim kako je rad u ovom e-tečaju važan za moje znanje.	1	2	3	4	5
(IM2_7) Mislim kako sam poprilično dobro savladao(la) korištenje e-tečaja u odnosu na druge studente.	1	2	3	4	5
(IM2_8) Korištenje ovog e-tečaja bilo je zabavno.	1	2	3	4	5
(IM2_9) Osjećao(la) sam opušteno koristeći ovaj e-tečaj.	1	2	3	4	5
(IM2_9) Koristio(la) sam e-tečaj jer sam htio/htjela.	1	2	3	4	5
(IM2_10) Uživao(la) sam cijelo vrijeme rada u ovom e-tečaju.	1	2	3	4	5
(IM2_10) Mislim kako je ovaj e-tečaj važan.	1	2	3	4	5
(IM2_11) Nisam imao(la) izbor za korištenje ovog e-tečaja.	1	2	3	4	5
(IM2_12) Zadovoljan/zadovoljna sam sa svojom izvedbom na e-tečaju.	1	2	3	4	5
(IM2_13) Moguće je kako bi ovakav e-tečaj mogao poboljšati moje navike prilikom učenja.	1	2	3	4	5
(IM2_13) Bio(la) sam zabrinut prilikom rada u e-tečaju.	1	2	3	4	5
(IM2_14) Mislim kako korištenje e-tečaja nije bilo posebno zanimljivo.	1	2	3	4	5
(IM2_15) Osjećao(la) sam kako mogu raditi što želim prilikom korištenja e-tečaja.	1	2	3	4	5
(IM2_16) Osjećao(la) sam se vještim prilikom korištenja e-tečaja.	1	2	3	4	5
(IM2_16) Spreman/spremna sam ponovno koristiti ovakav e-tečaj u drugom nastavnom predmetu jer smatram kako je koristan.	1	2	3	4	5
(IM2_18) Osjećao(la) sam pritisak prilikom korištenja e-tečaja.	1	2	3	4	5
(IM2_19) Mislim kako je korištenje ovog e-tečaja bilo korisno za mene.	1	2	3	4	5
(IM2_19) Osjećao(la) sam kako sam morao(la) koristiti e-tečaj.	1	2	3	4	5
(IM2_20) Osjećao(la) sam se ugodno prilikom korištenja e-tečaja.	1	2	3	4	5
(IM2_21) Mislim kako bi korištenje ovog e-tečaja moglo imati pozitivan ishod za moje učenje.	1	2	3	4	5
(IM2_22) Nakon korištenja sustava na neko kraće vrijeme, osjećao(la) sam se prilično stručno.	1	2	3	4	5
(IM2_24) Osjećao(la) sam kako korištenje e-tečaja nije bio moj izbor.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, ni netočno 4 – uglavnom točno 5 – potpuno točno

Slika P. Primjer *anketnog upitnika* kreiranog za *predistraživanje* - 6. dio

A. Molimo da procijenite koliko sljedeće izjave odgovaraju Vašem mišljenju:

*(Koristite skalu za odgovore od **1 = Uopće se ne slažem** pa sve do **5 = U potpunosti se slažem**)*

Bolje sam motiviran/a uz ljepše dizajnirano korisničko sučelje.	1	2	3	4	5
Zabavno mi je sakupljati bodove za svoja postignuća.	1	2	3	4	5
Trenutno stanje vlastitog postignuća treba biti jasno vidljivo.	1	2	3	4	5
Trenutna povratna informacija mi je poželjna.	1	2	3	4	5
Zabavno mi je otkriti sve što se, u sustavu za učenje, otkriti može.	1	2	3	4	5
Bolje pamtim kroz igru.	1	2	3	4	5
Zabavno mi je istraživati granice sustava za učenje.	1	2	3	4	5
Preferiram dinamičan sustav za učenje.	1	2	3	4	5
Preferiram jednostavno korisničko sučelje.	1	2	3	4	5
Preferiram biti vođen/a kroz sustav za učenje.	1	2	3	4	5
Stres negativno utječe na moj interes za temom.	1	2	3	4	5
Preferiram statičan oblik nastavnih sadržaja.	1	2	3	4	5
Preferiram surađivati s drugim studentima kroz timski rad.	1	2	3	4	5
Preferiram dijeliti znanje i pomagati drugima studentima.	1	2	3	4	5
Zabavno mi je natjecati se s drugim studentima.	1	2	3	4	5
Volim igrati računalne igre u slobodno vrijeme.	1	2	3	4	5
Volim igrati edukacijske računalne igre.	1	2	3	4	5
Preferiram se uspoređivati s boljim studentima.	1	2	3	4	5
Volim osjećaj svojeg napretka kroz sustav.	1	2	3	4	5

*(Koristite skalu za odgovore od **1 = Uopće se ne slažem** pa sve do **5 = U potpunosti se slažem**)*

Slika Q. Primjer *anketnog upitnika* kreiranog za *predistraživanje* - 7. dio

B. Označite u kolikoj mjeri smatrate da...:

(Koristite skalu za odgovore od 1 = Uopće se ne slažem pa sve do 5 = U potpunosti se slažem)

... priča pomaže u boljem razumijevanju ciljeva učenja?	1	2	3	4	5
... individualni zadaci pomažu motiviranju studenata?	1	2	3	4	5
... individualni zadaci podižu interes za učenjem kod studenata?	1	2	3	4	5
... postepeno otkrivanje sadržaja pozitivno utječe na interes za temu?	1	2	3	4	5
... međusobna suradnja pozitivno utječe na Vaše učenje?	1	2	3	4	5
... natjecanje pozitivno utječe na Vaše učenje?	1	2	3	4	5
... vizualan dizajn pozitivno utječe na Vaše učenje?	1	2	3	4	5
... jednostavno grafičko sučelje pozitivno utječe na Vaše učenje?	1	2	3	4	5
... ambijent u sustavu pozitivno utječe na Vaše učenje?	1	2	3	4	5
... resursi u sustavu pozitivno utječu na Vaše učenje?	1	2	3	4	5
... pokazatelj preostalog vremena pozitivno utječe na Vaše učenje?	1	2	3	4	5
... nagrađivanje za postignuća pozitivno utječe na Vaše učenje?	1	2	3	4	5
... sakupljanje bodova pozitivno utječe na Vaše učenje?	1	2	3	4	5
... dodjela bedževa pozitivno utječe na Vaše učenje?	1	2	3	4	5
... dodjela certifikata pozitivno utječe na Vaše učenje?	1	2	3	4	5
... različite razine težine pozitivno utječe na Vaše učenje?	1	2	3	4	5
... trenutna povratna informacija pozitivno utječe na Vaše učenje?	1	2	3	4	5
... "Top 10" lista najboljih pozitivno utječe na Vaše učenje?	1	2	3	4	5
... evidencija aktivnosti pozitivno utječe na Vaše učenje?	1	2	3	4	5
... slobodan odabir materijala pozitivno utječe na Vaše učenje?	1	2	3	4	5
... raznolikost sadržaja pozitivno utječe na Vaše učenje?	1	2	3	4	5
... interaktivni materijali pozitivno utječu na Vaše učenje?	1	2	3	4	5

Zahvaljujem se na Vašem sudjelovanju!

PRILOG 4. ANKETNI UPITNIK MOTIVACIJE I ZADOVOLJSTVA IZ PRVOG I DRUGOG GLAVNOG ISTRAŽIVANJA

ISTRAŽIVANJE UVJETA E-UČENJA

ANKETNI UPITNIK – 2015 – V2

Uputa

Prezime i ime:

Dvaj upitnik je dobrovoljan. Nakon što ga popunite i predate anketaru, smatramo da ste suglasni s korištenjem vaših odgovora za potrebe znanstvenog istraživanja i statističke obrade podataka. Predviđeno vrijeme za popunjavanje upitnika je oko 20-25 minuta, a pitanja su uglavnom koncipirana tako da treba označiti u kojoj mjeri se na Vas odnose pojedine tvrdnje.

MOLIMO DA ZAOKRUŽIVANJEM ODGOVORITE NA SLJEDEĆE TVRDNJE.

Dob: a) 18 g. b) 19 g. c) 20 g. d) 21 g. e) 22 g. f) 23 i više g.

Spol: a) muško b) žensko

KOLIKO DUGO KORISTITE SLJEDEĆE RAČUNALNE, INTERNETSKE I DRUGE TEHNOLOGIJE:

Računalo kod kuće: ne koristim do godinu dana 2-3 godine 4-5 godina 6-10 godina više od 10 godina

Internet kod kuće: ne koristim do godinu dana 2-3 godine 4-5 godina 6-10 godina više od 10 godina

KOLIKO MNOGO (U PROSJEKU) KORISTITE SLJEDEĆE TEHNOLOGIJE KOD KUĆE I NA FAKULTETU:

Računalo kod kuće: nekoliko puta tjedno manje od 1 sata svakodnev. 1-2 sata dnev. 3-5 sata dnev. 6 i više sati dnev.

Računalo na fakult.: nekoliko puta tjedno manje od 1 sata svakodnev. 1-2 sata dnev. 3-5 sata dnev. 6 i više sati dnev.

Internet kod kuće: nekoliko puta tjedno manje od 1 sata svakodnev. 1-2 sata dnev. 3-5 sata dnev. 6 i više sati dnev.

Internet na fakult.: nekoliko puta tjedno manje od 1 sata svakodnev. 1-2 sata dnev. 3-5 sata dnev. 6 i više sati dnev.

KOLIKO DUGO KORISTITE SLJEDEĆE TEHNOLOGIJE:

E-mail: ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

Forum: ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

Videokonferencije i webinare: ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

Web 2.0 (npr. wiki, blog): ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

Facebook i društvene mreže: ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

Neki sustav za e-učenje (npr. Moodle ili drugi):

ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

KOLIKO MNOGO (U PROSJEKU) KORISTITE TEHNOLOGIJE E-UČENJA (Moodle ili sl.):

Kod kuće: nekoliko puta tjedno manje od 1 sata svakodnev. 1-2 sata dnev. 3-5 sata dnev. 6 i više sati dnev.

Na fakult.: nekoliko puta tjedno manje od 1 sata svakodnev. 1-2 sata dnev. 3-5 sata dnev. 6 i više sati dnev.

Slika S. Primjer *anketnog upitnika* kreiranog za oba *glavna istraživanja* - 1. dio

KOLIKO DUGO KORISTITE SLJEDEĆE RESURSE ZA PRISTUP INTERNETU?

Mobilni Internet (npr. Vipnet stick): ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina
Internet sa širokopoljaskom vezom: ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina
Bežične lokalne mreže (WLAN): ne koristim do godinu dana 2-3 godine 4-5 godina više od 6 godina

Zadovoljstvo

(Q1) Uživao/la sam u korištenju e-tečaja.	1	2	3	4	5
(Q43) Estetske karakteristike e-tečaja nisu bile impresivne.	1	2	3	4	5
(Q47) Htlo sam istražiti sadržaje i mogućnosti e-tečaja.	1	2	3	4	5
(Q45) E-tečaj me nije uspio motivirati da ga nastavim koristiti.	1	2	3	4	5
(Q5) E-tečaj mi se učinio zabavnim.	1	2	3	4	5
(Q11) Rad se e-tečajem me je obradovao.	1	2	3	4	5
(Q6) Bilo mi je dosadno koristiti e-tečaj.	1	2	3	4	5
(Q21) Izgled e-tečaja meni je bio zanimljiv.	1	2	3	4	5
(Q39) Prema mojoj procjeni, osnovna nit vodilja (smisao) tečaja prilično je dosadna.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Pregled nad tečajem / navigacija

(Q18) Imao sam dobar pregled nad svim dijelovima e-tečaja.	1	2	3	4	5
(Q29) Uvijek sam znao(la) kako da ostvarim svoj cilj u e-tečaju.	1	2	3	4	5
(14) Izbornici (meniji) i drugi alati za upravljanje e-tečajem bili su vrlo upotrebljivi.	1	2	3	4	5
(Q25) Mislim da su načini upravljanja tečajem bili lako razumljivi (Intuitivni).	1	2	3	4	5
(GB1) Imao(la) sam probleme sa snalaženjem u tečaju / kretanjem kroz tečaj.	1	2	3	4	5
(28) Uvijek sam znao kako postići ono što želim koristeći izbornik i druge opcije unutar e-tečaja.	1	2	3	4	5
(15) Uvijek sam znao(la) kako se kretati unutar e-tečaja.	1	2	3	4	5
(37) Nisam se uvijek mogao(la) snaći s izbornikom (menijem) i poveznicama (linkovima) unutar e-tečaja.	1	2	3	4	5
(Q44) Sustav e-tečaja omogućavao je dobar pregled svih sadržaja i aktivnosti u tečaju.	1	2	3	4	5
(Q30) Događalo se da se izgubim (izgubim „orijentaciju“) koristeći mogućnosti e-tečaja.	1	2	3	4	5
(Q37) Nisam mogao „pronaći svoj put“ u e-tečaju.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Feedback (GB)

(F1) Dobljavao(la) sam dovoljno povratnih informacija o svojim rezultatima prilikom rada sa e-tečajem.	1	2	3	4	5
(F2) Kod svake, pa i najmanje aktivnosti u e-tečaju dobljavao/dobljava sam povratnu informaciju o mojem učinku/uspjehu.	1	2	3	4	5
(F3) Dobljavao(la) sam informaciju o svojem statusu tijekom rada s e-tečajem (npr. rezultatu u nekoj aktivnosti u odnosu na druge).	1	2	3	4	5
(Kov23) Povratne informacije tijekom rada s e-tečajem dobljavao(la) sam odmah ili vrlo brzo po završetku aktivnosti.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Slika T. Primjer *anketnog upitnika* kreiranog za oba *glavna istraživanja* - 2. dio

Zaokupljenost /uživljavanje

(Q13) Usplo/uspjela sam se jako uživjeti u e-tečaja.	1	2	3	4	5
(Q20) Nisam gubio(la) osjećaj za vrijeme tijekom rada sa e-tečajem.	1	2	3	4	5
(C1) E-tečaj je jako privlačio moju pozornost.	1	2	3	4	5
(3) Bio/bila sam usredotočen(a) na zadatke u e-tečaju.	1	2	3	4	5
(Q41) Dok sam koristio(la) e-tečaj, razmišljao(la) sam o stvarima koje <u>nisu</u> povezane sa e-tečajem.	1	2	3	4	5
(Q4) Mogao(la) sam se polstovjetiti s drugim korisnicima e-tečaja.	1	2	3	4	5
(C6) Tijekom rada s e-tečajem <u>nije</u> bilo moguće skrenuti moju pozornost sa zadataka u tečaju.	1	2	3	4	5
(Q3) Špontano sam se fokusirao/fokusirala na e-tečaj.	1	2	3	4	5
(C2) Sadržaj e-tečaja povećavao je moju usredotočenost.	1	2	3	4	5
(4) Nisam mogao(la) zblížiti se s drugim sudionicima e-tečaja.	1	2	3	4	5
(23) Znao mi se dogoditi da zaboravim na protok vremena prilikom korištenja e-tečaja.	1	2	3	4	5
(16) Emocionalno sam se jako aktivirao(la) prilikom rada s e-tečajem.	1	2	3	4	5
(41) Prilikom rada s e-tečajem moje misli su znale odlutati na druge teme ili sam započinjao(la) druge aktivnosti koje nisu bile vezane uz e-tečaj.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, ni netočno 4 – uglavnom točno 5 – potpuno točno

Priprema / uputa za rad s e-tečajem (GB)

(GB1) Uputa za rad s izbornicima (menjima) i drugim funkcionalnostima bila je jasna i dovoljno detaljna.	1	2	3	4	5
(16) U e-tečaju je bilo dobro objašnjeno kako treba prilagoditi postavke e-tečaja (profil korisnika, pretplatu na forume i sl.).	1	2	3	4	5
(36) Izbornici (menji) e-tečaja bili su teški za svladavanje i korištenje.	1	2	3	4	5
(37) Zbog loše upute nisam se uvijek mogao(la) snaći s izbornikom (menjem) i poveznicama (linkovima) unutar e-tečaja.	1	2	3	4	5
(Q19) E-tečaj mi je omogućio korištenje pomoćnih informacija („help“) u pravim trenucima.	1	2	3	4	5
(G1) Opći ciljevi e-tečaja dobro su predstavljeni na njegovom početku.	1	2	3	4	5
(G4) Ciljevi za pojedine faze rada s e-tečajem bili su jasni i dovoljno često istaknuti.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, ni netočno 4 – uglavnom točno 5 – potpuno točno

Primjerena težina e-tečaja (GB)

(Q10) E-tečaj mi je bio lagan za svladati.	1	2	3	4	5
(Q48) Težina tečaja za mene je bila primjerena.	1	2	3	4	5
(GB2) Dijelovi e-tečaja za mene su bili preteški.	1	2	3	4	5
(48) Težina e-tečaja nije bila prihvatljiva u odnosu na moje sposobnosti.	1	2	3	4	5
(GB3) Gradivo e-tečaja <u>nije</u> bilo presloženo za razumjeti.	1	2	3	4	5
(GB4) Kad bih imao(la) dovoljno vremena, svi sadržaji tečaja bili bi mi lagani za svladati.	1	2	3	4	5
(Q22) Kontrolne funkcije za korištenje e-tečaja bile su mi prekomplikirane.	1	2	3	4	5
(C8) Količina opterećenja za svladavanje e-tečaja bila je primjerena.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, ni netočno 4 – uglavnom točno 5 – potpuno točno

Slika U. Primjer *anketnog upitnika* kreiranog za oba *glavna istraživanja* - 3. dio

Razni motivacijski poticaji

(38) Načini motiviranja studenata na svladavanje e-tečaja bili su dovoljno različiti.	1	2	3	4	5
(Q38) Mogućnosti e-tečaja učinile su mi se dovoljno izazovnim (poticajnim).	1	2	3	4	5
(P1) E-tečaj posjeduje jasnu i organiziranu strukturu nastavnog materijala koja potiče na rad sa tečajem.	1	2	3	4	5
(P2) E-tečaj sam dobro iskoristio jer je za mene bio motivirajući.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Molimo da procijeniti koliko su Vas sljedeći elementi potaknuli da s više zalaganja i motiva svladavate sadržaje e-tečaja. Prilikom procjene koristite sljedeću skalu u rasponu od 1 – 7:

1-nimalo 2- vrlo malo 3-malo / ispodprosječno 4-prosječno / umjereno 5-podosta / iznadprosječno 6-mnogo 7- vrlo mnogo

<input type="checkbox"/> Edukacijske igre	1	2	3	4	5	6	7
<input type="checkbox"/> Multimedijalni elementi	1	2	3	4	5	6	7
<input type="checkbox"/> Blog	1	2	3	4	5	6	7
<input type="checkbox"/> Forum	1	2	3	4	5	6	7
<input type="checkbox"/> Upitnici	1	2	3	4	5	6	7
<input type="checkbox"/> Chat	1	2	3	4	5	6	7
<input type="checkbox"/> Uređivanje profilne slike i osobnih informacija	1	2	3	4	5	6	7
<input type="checkbox"/> Bonus nastavni materijali	1	2	3	4	5	6	7
<input type="checkbox"/> Motivirajući smisao / Priča	1	2	3	4	5	6	7
<input type="checkbox"/> Vizualan status studentskih obveza	1	2	3	4	5	6	7
<input type="checkbox"/> Vizualan status studentskog napretka	1	2	3	4	5	6	7
<input type="checkbox"/> Vizualan status završenosti kolegija	1	2	3	4	5	6	7
<input type="checkbox"/> Nivo težine (eng. level)	1	2	3	4	5	6	7
<input type="checkbox"/> Trenutno ostvareni bodovi za završene aktivnosti	1	2	3	4	5	6	7
<input type="checkbox"/> Top lista najboljih studenata	1	2	3	4	5	6	7
<input type="checkbox"/> Bedževi za postignuća	1	2	3	4	5	6	7
<input type="checkbox"/> Bodovi za postignuća	1	2	3	4	5	6	7
<input type="checkbox"/> Certifikati za postignuća	1	2	3	4	5	6	7

Interakcija

(S1) Osjećao(la) sam se povezano s drugim korisnicima e-tečaja.	1	2	3	4	5
(S2) Vrlo dobro sam surađivao s drugim korisnicima e-tečaja.	1	2	3	4	5
(S3) Suradnja s drugim korisnicima e-tečaja bila mi je korisna u učenju.	1	2	3	4	5
(S4) E-tečaj je dobro podržavao socijalnu interakciju između korisnika (npr. chat, forum).	1	2	3	4	5
(S5) E-tečaj je primjereno podržavao komunikaciju među korisnicima unutar samog sustava vezanu uz učenje gradiva.	1	2	3	4	5
(P9) Bilo je moguće jednostavno i brzo prenositi informacije i znanja između studenata / korisnika e-tečaja.	1	2	3	4	5
(P10) Mogao(la) sam koristiti mnogo različitih komunikacijskih alata za razmjenu informacija s drugim studentima	1	2	3	4	5
(P11) E-tečaj je omogućavao kooperativno učenje i grupni rad s ostalim korisnicima sustava.	1	2	3	4	5
(P12) E-tečaj mi je omogućavao osobno stupanje u kontakt s pojedinim studentima.	1	2	3	4	5
(Q42) Moj položaj i ovlasti u tečaju nisu mi omogućavali uvid u to što rade i postižu drugi korisnici e-tečaja.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Slika V. Primjer anketnog upitnika kreiranog za oba glavna istraživanja - 4. dio

Postignuće učenja

(K1) Korištenje e-tečaja je povećalo moje znanje.	1	2	3	4	5
(K2) Saviadao(la) sam osnovne ideje vezane uz traženo znanje u sklopu e-tečaja.	1	2	3	4	5
(K3) Pokušao(la) sam vlastito znanje što više primijeniti u e-tečaju.	1	2	3	4	5
(K4) E-tečaj je motivirao korisnike za povezivanje naučenog znanja.	1	2	3	4	5
(K5) Htio/htjela sam što više znati više o predmetu/znanju koje se poučavalo e-tečajem.	1	2	3	4	5
(P18) E-tečaj je dobro omogućavao stjecanje znanja i vještina o promatranoj temi.	1	2	3	4	5
(P19) E-tečaj je omogućavao stjecanje vještina za praktičnu primjenu znanja.	1	2	3	4	5
(P20) E-tečaj je omogućavao stjecanje vještina za komunikaciju i suradnju.	1	2	3	4	5
(48) Osjećao/osjećala sam da mogu nešto za mene korisno naučiti tijekom rada s e-tečajem.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Individualni proces učenja

(P13) E-tečaj mi je omogućavao slobodno korištenje resursa neovisno o vremenu i prostoru.	1	2	3	4	5
(P14) E-tečaj mi je omogućavao vlastiti odabir strategije i brzine učenja.	1	2	3	4	5
(P15) E-tečaj mi je omogućavao (samo)provjeru mogeg znanja na kraju svakog poglavlja i usporedbu s drugim studentima.	1	2	3	4	5
(P15) U e-tečaju sam mogao raditi onom brzinom/tempom kako sam htio i koliko mi je to odgovaralo.	1	2	3	4	5
(P16) E-tečaj mi je omogućavao kontroliranje ishoda/rezultata mogeg učenja.	1	2	3	4	5
(P16) Imao(la) sam mogućnost provjeravati koliko sam naučio(la) kad god sam to poželio/poželjela.	1	2	3	4	5
(P17) E-tečaj je vrlo dobro održavao moju motivaciju za učenjem.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Upitnik o doživljaju e-tečaja

(2) Bio(bila) sam frustriran(a) na kraju e-tečaja.	1	2	3	4	5
(6) Osjećao(la) sam da imam kontrolu prilikom korištenja e-tečaja.	1	2	3	4	5
(9) Mogao / mogla sam na ekranu vidjeti sve informacije koje su mi potrebne prilikom korištenja e-tečaja.	1	2	3	4	5
(11) Znao(la) sam što sam u svakom trenutku što sam trebao(la) raditi u e-tečaju.	1	2	3	4	5
(12) Bilo je trenutaka kada nisam ništa radio(la) u e-tečaju.	1	2	3	4	5
(13) Sviđao mi se izgled e-tečaja.	1	2	3	4	5
(14) Grafičko sučelje e-tečaja bilo je pregledno.	1	2	3	4	5
(15) Mnoge stvari mi se nisu dopale u vezi e-tečaja.	1	2	3	4	5
(25) Mislim kako je kretanje kroz e-tečaj bilo lako shvatljivo.	1	2	3	4	5
(26) Grafičko sučelje e-tečaja bilo je prikladno ovakvom tipu sustava za učenje.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni točno, niti netočno 4 – uglavnom točno 5 – potpuno točno

Slika W. Primjer *anketnog upitnika* kreiranog za oba *glavna istraživanja* - 5. dio

Upitnik za evaluaciju e-tečaja

1 – potpuno netočno 2 – uglavnom netočno 3 – ni tačno, niti netočno 4 – uglavnom tačno 5 – potpuno tačno

(IM2_1) Dok sam koristio e-tečaj razmišljao(la) sam kako sam uživao(la).	1	2	3	4	5
(IM2_2) Mislim kako sam imao mogućnost odabra koristiti e-tečaj.	1	2	3	4	5
(IM2_2) Nisam se osjećao(la) živčanim prilikom korištenja e-tečaja.	1	2	3	4	5
(IM2_3) Osjećao(la) sam kako je rad u e-tečaju moj odabir.	1	2	3	4	5
(IM2_4) Mislim kako sam poprilično dobar/dobra u savladavanju ovog e-tečaja.	1	2	3	4	5
(IM2_4) Mislim kako je korištenje ovog e-tečaja korisno za poboljšanje koncentracije.	1	2	3	4	5
(IM2_5) Mislim kako je e-tečaj vrlo zanimljiv.	1	2	3	4	5
(IM2_6) Povremeno sam se osjećao(la) nervozno prilikom korištenja e-tečaja.	1	2	3	4	5
(IM2_6) Mislim kako je rad u ovom e-tečaju važan za moje znanje.	1	2	3	4	5
(IM2_7) Mislim kako sam poprilično dobro savladao(la) korištenje e-tečaja u odnosu na druge studente.	1	2	3	4	5
(IM2_8) Korištenje ovog e-tečaja bilo je zabavno.	1	2	3	4	5
(IM2_9) Osjećao(la) sam opušteno koristeći ovaj e-tečaj.	1	2	3	4	5
(IM2_9) Koristio(la) sam e-tečaj jer sam htio/htjela.	1	2	3	4	5
(IM2_10) Uživao(la) sam cijelo vrijeme rada u ovom e-tečaju.	1	2	3	4	5
(IM2_10) Mislim kako je ovaj e-tečaj važan.	1	2	3	4	5
(IM2_12) Zadovoljan/zadovoljna sam sa svojom izvedbom na e-tečaju.	1	2	3	4	5
(IM2_13) Moguće je kako bi ovakav e-tečaj mogao poboljšati moje navike prilikom učenja.	1	2	3	4	5
(IM2_13) Bio(la) sam zabrinut prilikom rada u e-tečaju.	1	2	3	4	5
(IM2_14) Mislim kako korištenje e-tečaja nije bilo posebno zanimljivo.	1	2	3	4	5
(IM2_15) Osjećao(la) sam kako mogu raditi što želim prilikom korištenja e-tečaja.	1	2	3	4	5
(IM2_16) Osjećao(la) sam se vještim prilikom korištenja e-tečaja.	1	2	3	4	5
(IM2_16) Spreman/spremna sam ponovno koristiti ovakav e-tečaj u drugom nastavnom predmetu jer smatram kako je koristan.	1	2	3	4	5
(IM2_18) Osjećao(la) sam pritisak prilikom korištenja e-tečaja.	1	2	3	4	5
(IM2_19) Mislim kako je korištenje ovog e-tečaja bilo korisno za mene.	1	2	3	4	5
(IM2_20) Osjećao(la) sam se ugodno prilikom korištenja e-tečaja.	1	2	3	4	5
(IM2_21) Mislim kako bi korištenje ovog e-tečaja moglo imati pozitivan ishod za moje učenje.	1	2	3	4	5
(IM2_22) Nakon korištenja sustava na neko kraće vrijeme, osjećao(la) sam se prilično stručno.	1	2	3	4	5
(IM2_24) Osjećao(la) sam kako korištenje e-tečaja nije bio moj izbor.	1	2	3	4	5

1 – potpuno netočno 2 – uglavnom netočno 3 – ni tačno, niti netočno 4 – uglavnom tačno 5 – potpuno tačno

Slika X. Primjer *anketnog upitnika* kreiranog za oba *glavna istraživanja* - 6. dio

Nastavak *anketnog upitnika motivacije i zadovoljstva* identičan je kao što je ranije prikazano na slikama **Q** i **R** koje se nalaze unutar ovog priloga, te se zbog redundantnosti neće ponovno navoditi u nastavku ove doktorske disertacije.

Faktorska analiza načinjena je nad 11 skala *anketnog upitnika* koji je korišten u *prvom i drugom glavnom istraživanju*. Korištena je metoda glavnih komponenata uz *varimax* rotaciju skala čiji se rezultat prikazuje u **tablici P.1.** u nastavku ovog rada. Rezultati su pokazali da se rotirani faktori 100% poklapaju s mjernim skalama. Zadovoljen je i kriterij gdje je bruto vrijednost konstrukta na odgovarajući faktor za **0.30 jedinica** veći od prve sljedeće korelacije neke druge skale na isti faktor. Navedeno je opisano ranije u poglavlju 5.4.1. ove doktorske disertacije. Uz analizu Cronbach Alpha koeficijenta koji su također ranije opisani u ovom radu za svako istraživanje posebno, može se zaključiti kako je predmet mjerenja većine skala **jedinstven**, tj. da među njihovim predmetima mjerenja nema prevelikih preklapanja.

Tablica P.1. Faktorska analiza *anketnog upitnika* za podatke iz *prvog glavnog istraživanja* (N=182)

Redni brojevi, kodne oznake i nazivi i mjernih skala u anketi		Faktor u rotiranoj faktorskoj matrici										
		1	2	3	4	5	6	7	8	9	10	11
1. SUM_POT - Razni motivacijski poticaji	SUM_POT	,785	,237	,231	,265	,170	,228	,199	,198	,143	,127	,086
2. SUM_TEZ - Primjerena težina tečaja*	SUM_TEZ	,205	,860	,169	,160	,210	,165	,185	,177	,120	,084	,069
3. SUM_FDB - <i>Feedback</i> (studentu iz tečaja)*	SUM_FDB	,231	,190	,815	,188	,236	,205	,186	,206	,131	,111	,078
4. SUM_UZI - Zaokupljenost/uživljavanje	SUM_UZI	,346	,229	,239	,721	,200	,220	,252	,227	,135	,145	,089
5. SUM_NAV - Navigacija	SUM_NAV	,200	,346	,332	,202	,704	,267	,218	,202	,098	,129	,089
6. SUM_ZAD - Zadovoljstvo	SUM_ZAD	,301	,253	,285	,231	,273	,706	,199	,237	,133	,126	,088
7. SUM_UPT - Priprema / uputa za rad s tečajem*	SUM_UPT	,277	,322	,268	,288	,240	,210	,683	,222	,133	,143	,097
8. SUM_IND - Individualni proces učenja	SUM_IND	,278	,295	,303	,250	,216	,248	,217	,692	,151	,131	,080
9. SUM_POS - Postignuće učenja	SUM_POS	,483	,327	,299	,231	,149	,213	,199	,245	,557	,184	,079
10. SUM_INT - Interakcija (studenta s tečajem)	SUM_INT	,451	,203	,269	,315	,255	,232	,263	,233	,215	,531	,112
11. SUM_DOZ - Upitnik o doživljaju tečaja	SUM_DOZ	,339	,307	,325	,288	,366	,257	,341	,205	,134	,180	,441

PRILOG 5. ANALIZA REZULTATA OBRADJE PODATAKA U PROVEDENOM PREDISTRAŽIVANJU

Predtest analiza rezultata u provedenom predistraživanju

U ovom prilogu nalazi se analiza prosječnih rezultata *predtesta* iz provedenog *predistraživanja* koje je prikazano u poglavlju 6.1.1.

Tablica P.2. Rezultati *predtesta* za **prvu eksperimentalnu (G1)** grupu ispitanika (N =15)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	14,53	4,63	11	8-24

Tablica prikazuje rezultate *predtesta* za provjeru znanja kod prve *eksperimentalne (G1)* grupe ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 14,53 uz standardnu devijaciju od 4,63. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 11. Raspon bodova kreće se od minimalno 8 do maksimalno 24. Ukupan broj mogućih bodova iznosi 32.

Tablica P.3. Rezultati *predtesta* za **drugu eksperimentalnu (G4)** grupu ispitanika (N=13)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	17,69	5,47	15	10-28

Tablica prikazuje rezultate *predtesta* za provjeru znanja kod druge *eksperimentalne (G4)* grupe ispitanika. Svako pitanje nosi jedan bod, što čini ukupan broja bodova 32. Prosječna vrijednost bodova koje je grupa sakupila iznosi 17,69 uz standardnu devijaciju od 5,47. Najčešći iznos (Mod) sakupljenih bodova je 15. Raspon bodova koji su ispitanici ostvarili iznosi od 10 do 28.

Tablica P.4. Rezultati *predtesta* za **prvu kontrolnu (G2)** grupu ispitanika (N =13)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	13,31	3,25	14	8-18

Prikazani rezultati *predtesta* za provjeru znanja odnose se na prvu *kontrolnu (G2)* grupu ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 13,31 uz standardnu devijaciju od 3,25. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 14. Raspon bodova kreće se od minimalno 8 do maksimalno 18.

Tablica P.5. Rezultati *predtesta* za **drugu kontrolnu (G3)** grupu ispitanika (N =14)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	17,29	4,71	16	9-26

Rezultati *predtesta* za provjeru znanja kod druge *kontrolne (G3)* grupe ispitanika, prikazani su u tablici P.5. Od ukupnog broja bodova, druga kontrolna grupa ostvarila je prosječnu vrijednost bodova u iznosu od 17,29 uz standardnu devijaciju od 4,71. Najčešći iznos (Mod) sakupljenih bodova iznosi 16. Raspon bodova koji su ispitanici ostvarili iznosi od 9 do 26.

Posttest analiza rezultata u provedenom predistraživanju

U ovom prilogu nalazi se analiza prosječnih rezultata *posttesta* iz provedenog *predistraživanja* koje je prikazano u poglavlju 6.1.2.

Tablica P.6. Rezultati *posttesta* za **prvu eksperimentalnu (G1)** grupu ispitanika (N =15)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	20,40	5,74	14	12-29

Tablica prikazuje rezultate *posttesta* za provjeru znanja kod prve *eksperimentalne (G1)* grupe ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 20,40 uz standardnu devijaciju od 5,74. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 14. Raspon bodova kreće se od minimalno 12 do maksimalno 29. Ukupan broj mogućih bodova iznosi 32.

Tablica P.7. Rezultati *posttesta* za **drugu eksperimentalnu (G4)** grupu ispitanika (N=13)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	21,46	5,99	21	9-30

Rezultati *posttesta* za provjeru znanja kod druge *eksperimentalne (G4)* grupe ispitanika, prikazani su u tablici P.7. Prosječna vrijednost bodova koje je grupa sakupila iznosi 21,46 uz standardnu devijaciju od 5,99. Najčešći iznos (Mod) sakupljenih bodova iznosi 21. Raspon bodova koji su ispitanici ostvarili iznosi od 9 do 30.

Tablica P.8. Rezultati *posttesta* za **prvu kontrolnu (G2)** grupu ispitanika (N =13)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	15,15	2,54	13	12-20

Prikazani rezultati *predtesta* za provjeru znanja odnose se na prvu kontrolnu (G2) grupu ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 15,15 uz standardnu devijaciju od 2,54. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 13. Raspon bodova kreće se od minimalno 12 do maksimalno 20.

Tablica P.9. Rezultati *posttesta* za **drugu kontrolnu (G3)** grupu ispitanika (N =14)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
32	15,43	5,84	17	5-24

Tablica P.9. prikazuje rezultate *posttesta* za provjeru znanja kod druge kontrolne (G3) grupe ispitanika. Od ukupnog broja bodova, druga kontrolna grupa ostvarila je prosječnu vrijednost bodova u iznosu od 15,43 uz standardnu devijaciju od 5,84. Najčešći iznos (Mod) sakupljenih bodova iznosi 17. Raspon bodova koji su ispitanici ostvarili iznosi od 5 do 24.

Rezultat analize unutarnje konzistentnosti skala u provedenom *predistraživanju*

S obzirom na odnos između čestica u skali i dobivenog koeficijenta unutarnje konzistentnosti (CA) za sve skale navode se tablice (P.10. do P.23.) analiza unutarnjih konzistentnosti skala.

Tablica P.10. Skala: **Zadovoljstvo korištenja e-tečaja** (CA = ,892)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
ZAD_1	,795	,870
ZAD_2R	,359	,902
ZAD_3	,579	,885
ZAD_4R	,320	,904
ZAD_5	,845	,862
ZAD_6	,820	,864
ZAD_7R	,805	,867
ZAD_8	,796	,867
ZAD_9R	,562	,886

Tablica P.11. Skala: Pregled nad tečajem / navigacija (CA = ,944)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbací
NAV_1	,839	,937
NAV_2	,755	,939
NAV_3	,825	,937
NAV_4	,797	,938
NAV_5R	,656	,942
NAV 6	,559	,944
NAV_7	,741	,940
NAV_8	,759	,939
NAV_9R	,715	,940
NAV 10R	,534	,945
NAV 11	,562	,944
NAV_12	,791	,938
NAV_13R	,685	,941
NAV_14R	,833	,937

Statistički izračun i logički smisao pitanja uključeni su u analizu čestica svake skale iz provedenog *anketnog upitnika*. U skali **Zadovoljstvo korištenja e-tečaja** nije evidentirana niti jedna čestica koja bi trebala biti korigirana niti je brisana iz provedenog *anketnog upitnika*. Skala pod nazivom **Pregled nad tečajem / navigacija** sadrži dvije čestice koje su u potpunosti obrisane iz *anketnog upitnika*. Ostale čestice nisu korigirane niti mijenjane na bilo koji način, te se prenose u *anketni upitnik prvog glavnog istraživanja*.

Tablica P.12. Skala: Povratne informacije u e-tečaju (CA = ,934)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbací
FDB_1	,844	,915
FDB_2	,875	,905
FDB_3	,824	,921
FDB_4	,839	,916

Tablica P.132. Skala: **Zaokupljenost / uživanje** (CA = ,852)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
UZI_1	,794	,825
UZI_2R	,180	,858
UZI_3	,832	,822
UZI_4	,678	,832
UZI_5R	,440	,845
UZI_6	,612	,836
UZI_7	,610	,836
UZI_8	-.096	,875
UZI_9	,643	,834
UZI_10	,725	,830
UZI_11R	-.255	,883
UZI_12R	,571	,837
UZI_13	,521	,840
UZI_14	,595	,838
UZI_15R	,694	,830

Tablica P.14. Skala: **Priprema / uputa za rad s e-tečajem** (CA = ,925)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
UPT_1	,525	,930
UPT_2	,864	,908
UPT_3	,823	,911
UPT_4R	,585	,926
UPT_5R	,691	,919
UPT_6R	,788	,913
UPT_7	,633	,922
UPT_8	,839	,909
UPT_9	,843	,909

U skalama **Zaokupljenost / uživanje** i **Priprema / uputa za rad s e-tečajem** izbačene su po dvije čestice iz *anketnog upitnika* prije primjene u *prvom glavnom istraživanju*.

Tablica P.15. Skala: Primjerena težina e-tečaja (CA = ,866)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
TEZ_1	,818	,826
TEZ_2	,760	,833
TEZ_3R	,720	,838
TEZ_4R	,522	,861
TEZ_5	,391	,875
TEZ_6	,429	,868
TEZ_7R	,673	,844
TEZ_8	,649	,846

Tablica P.16. Skala: Motivacijski poticaji (CA = ,712)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
POT_1	,566	,624
POT_2R	-.014	,842
POT_3	,671	,579
POT_4	,669	,576
POT_5	,590	,618

Tablica P.17. Skala: Agregacija elemenata za motivacijske poticaje (CA = ,957)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
GEM_1	,619	,957
GEM_2	,813	,954
GEM_3	,661	,956
GEM_4	,531	,958
GEM_5	,550	,958
GEM_6	,621	,957
GEM_7	,785	,954
GEM_8	,694	,956
GEM_9	,797	,954
GEM_10	,858	,953
GEM_11	,884	,952
GEM_12	,793	,954
GEM_13	,873	,953
GEM_14	,688	,956
GEM_15	,683	,956
GEM_16	,812	,954
GEM_17	,766	,954
GEM_18	,674	,956

Tablica P.18. Skala: Interakcija unutar e-tečaja (CA = ,903)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
INT_1	,800	,887
INT_2	,633	,895
INT_3	,550	,899
INT_4	,784	,886
INT_5	,844	,883
INT_6	,790	,885
INT_7	,803	,884
INT_8	,782	,887
INT_9	,638	,895
<u>INT_10</u>	<u>,170</u>	<u>,918</u>
INT_11R	,334	,911

Tablica P.19. Skala: Postignuće učenja (CA = ,935)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
POS_1	,731	,929
POS_2	,696	,931
POS_3	,547	,939
POS_4	,795	,925
POS_5	,747	,928
POS_6	,828	,924
POS_7	,827	,923
POS_8	,781	,926
POS_9	,859	,921

Tablica P.20. Skala: Individualni proces učenja (CA = ,913)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
IND_1	,726	,901
IND_2	,735	,900
IND_3	,708	,903
IND_4	,752	,898
IND_5	,721	,902
IND_6	,733	,901
IND_7	,776	,896

U skali pod nazivom **Motivacijski poticaji** uklonjena je jedna čestica, dok su dvije izmijenjene (POT_4 i POT_5). U skali pod nazivom **Interakcija unutar e-tečaja** uklonjena je jedna čestica dok ostale čestice niti nisu mijenjane.

Tablica P.21. Skala: **Doživljaj e-tečaja** (CA = ,902)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
DOZ_1R	,741	,887
DOZ_2	,728	,890
DOZ_3	,731	,888
DOZ_4R	,060	,922
DOZ_5	,702	,890
DOZ_6R	,267	,912
DOZ_7	,874	,877
DOZ_8	,847	,880
DOZ_9R	,521	,900
DOZ_10	,756	,887
DOZ_11	,864	,879

Tablica P.22. Skala: **Evaluacija e-tečaja** (CA = ,973; za čestice od 1 do 15)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
EVA_1	,715	,972
EVA_2	,840	,972
EVA_3	,824	,972
EVA_4	,846	,972
EVA_5	,540	,973
EVA_6	,882	,971
EVA_7	,920	,971
EVA_8R	,475	,974
EVA_9	,542	,973
EVA_10	,598	,973
EVA_11	,885	,971
EVA_12	,884	,971
EVA_13	,865	,972
EVA_14	,918	,971
EVA_15	,754	,972

Unutar skale pod nazivom **Doživljaj e-tečaja**, jedna čestica je uklonjena, dok je čestica pod kodnom oznakom DOZ_2 prilagođena za korištenje unutar *anketnog upitnika* glavnog istraživanja. Skala pod nazivom **Evaluacija e-tečaja** podijeljena je na dva dijela zbog velikog broja čestica. Ostatak skale pod nazivom **Evaluacija e-tečaja** nalazi se u nastavku rada.

Tablica P.23. Skala: **Evaluacija e-tečaja** ($CA = ,973$; za čestice od 16 do 30)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbací
EVA_16R	,101	,976
EVA_17	,523	,973
EVA_18	,704	,972
EVA_19R	,638	,973
EVA_20R	,523	,974
EVA_21	,833	,972
EVA_22	,700	,972
EVA_23	,923	,971
EVA_24R	,626	,973
EVA_25	,878	,971
EVA_26R	,677	,973
EVA_27	,905	,971
EVA_28	,829	,972
EVA_29	,834	,972
EVA_30R	,718	,972

U drugom dijelu skale pod nazivom **Evaluacija e-tečaja** izbačene je su dvije čestice, dok ostale nisu mijenjane. Slijedi analiza rezultata *eksperimentalne* i *kontrolne* grupe u provedenom *predistraživanju* s obzirom na **korigirane skale** i **njihove čestice**.

Tablica P.24. Analiza skala **druge cjeline** *anketnog upitnika* u provedenom *predistraživanju* nakon isključivanja neodgovarajućih čestica iz skala (N=50)

Naziv skale	Broj čestica	Prosječna vrijednost	Standardna devijacija σ	Raspon odgovora	Cronbach alpha koef.
Zadovoljstvo korištenja e-tečaja	9	2,99	1,30	1-5	,892
Pregled nad tečajem / navigacija	11	3,05	1,21	1-5	,946
Povratne informacije u e-tečaju	4	3,21	1,37	1-5	,934
Zaokupljenost / uživanje	13	2,76	1,24	1-5	,907
Priprema / uputa za rad s e-tečajem	7	2,60	1,24	1-5	,932
Primjerena težina e-tečaja	8	3,17	1,39	1-5	,866
Motivacijski poticaji	4	3,09	1,25	1-5	,842
Agregacija elemenata za motivacijske poticaje	18	3,75	2,18	1-7	,957
Interakcija unutar e-tečaja	10	2,52	1,29	1-5	,918
Postignuće učenja	9	3,02	1,28	1-5	,935
Individualni proces učenja	7	3,09	1,40	1-5	,913
Doživljaj e-tečaja	10	3,23	1,40	1-5	,922
Evaluacija e-tečaja	28	2,92	1,36	1-5	,976

PRILOG 6. ANALIZA REZULTATA OBRADJE PODATAKA U PROVEDENOM PRVOM GLAVNOM ISTRAŽIVANJU

Pretest analiza rezultata u provedenom prvom glavnom istraživanju

U ovom prilogu nalazi se analiza prosječnih rezultata *pretesta* iz provedenog *prvog glavnog istraživanja* koje je prikazano u poglavlju 6.2.1.

Tablica P.25. Rezultati *pretesta* za **prvu eksperimentalnu (G2)** grupu ispitanika (N =15)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	15,60	4,56	15	6-26

Tablica P.25. prikazuje rezultate *pretesta* za provjeru znanja kod prve *eksperimentalne (G2)* grupe ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 15,60 uz standardnu devijaciju od 4,56. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 15. Raspon bodova kreće se od minimalno 6 do maksimalno 26. Ukupan broj mogućih bodova iznosi 30.

Tablica P.26. Rezultati *pretesta* za **drugu eksperimentalnu (G3)** grupu ispitanika (N=14)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	17,29	2,61	19	12-21

Tablica prikazuje rezultate *pretesta* za provjeru znanja kod druge *eksperimentalne (G3)* grupe ispitanika. Svako pitanje nosi jedan bod, što čini ukupan broja bodova 30. Prosječna vrijednost bodova koje je grupa sakupila iznosi 17,29 uz standardnu devijaciju od 2,61. Najčešći iznos (Mod) sakupljenih bodova je 19. Raspon bodova koji su ispitanici ostvarili iznosi od 12 do 21.

Tablica P.27. Rezultati *pretesta* za **treću eksperimentalnu (G5)** grupu ispitanika (N =15)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	15,00	3,53	15	10-24

Rezultati *pretesta* za provjeru znanja kod treće *eksperimentalne (G5)* grupe ispitanika prikazani su u tablici P.27. Prosječna vrijednost bodova koju je grupa postigla iznosi 15,00 uz standardnu devijaciju od 3,53. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 15. Raspon bodova kreće se od minimalno 10 do maksimalno 24.

Tablica P.28. Rezultati *predtesta* za **četvrtu eksperimentalnu (G7)** grupu ispitanika (N =13)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	14,92	4,26	16	8-24

Tablica prikazuje rezultate *predtesta* za provjeru znanja kod četvrte *eksperimentalne (G7)* grupe ispitanika. Od ukupnog broja bodova, četvrta eksperimentalna grupa ostvarila je prosječnu vrijednost bodova u iznosu od 14,92 uz standardnu devijaciju od 4,26. Najčešći iznos (Mod) sakupljenih bodova iznosi 16. Raspon bodova koji su ispitanici ostvarili iznosi od 8 do 24.

Tablica P.29. Rezultati *predtesta* za **petu eksperimentalnu (G11)** grupu ispitanika (N =13)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	14,31	3,61	10	9-20

Tablica prikazuje rezultate *predtesta* za provjeru znanja kod pete *eksperimentalne (G11)* grupe ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 14,31 uz standardnu devijaciju od 3,61. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 10. Raspon bodova kreće se od minimalno 9 do maksimalno 20. Ukupan broj mogućih bodova iznosi 30.

Tablica P.30. Rezultati *predtesta* za **šestu eksperimentalnu (G12)** grupu ispitanika (N=15)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	16,00	6,01	10	10-28

Tablica prikazuje rezultate *predtesta* za provjeru znanja kod šeste *eksperimentalne (G12)* grupe ispitanika. Svako pitanje nosi jedan bod, što čini ukupan broja bodova 30. Prosječna vrijednost bodova koje je grupa sakupila iznosi 16,00 uz standardnu devijaciju od 6,01. Najčešći iznos (Mod) sakupljenih bodova je 10. Raspon bodova koji su ispitanici ostvarili iznosi od 10 do 28.

Tablica P.31. Rezultati *predtesta* za **sedmu eksperimentalnu (G14)** grupu ispitanika (N =14)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	15,71	3,85	15	7-21

Rezultati *predtesta* za provjeru znanja kod sedme *eksperimentalne (G14)* grupe ispitanika, prikazani su u tablici P.31. Prosječna vrijednost bodova koju je grupa postigla iznosi 15,71 uz

standardnu devijaciju od 3,85. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 15. Raspon bodova kreće se od minimalno 7 do maksimalno 21.

Tablica P.32. Rezultati *predtesta* za **prvu kontrolnu (G1)** grupu ispitanika (N =15)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	17,07	3,17	17	11-23

Tablica P.32. prikazuje rezultate *predtesta* za provjeru znanja kod prve *kontrolne (G1)* grupe ispitanika. Od ukupnog broja bodova, prva kontrolna grupa ostvarila je prosječnu vrijednost bodova u iznosu od 17,07 uz standardnu devijaciju od 3,17. Najčešći iznos (Mod) sakupljenih bodova iznosi 17. Raspon bodova koji su ispitanici ostvarili iznosi od 11 do 23.

Tablica P.33. Rezultati *predtesta* za **drugu kontrolnu (G4)** grupu ispitanika (N=14)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	13,36	2,87	15	7-19

Tablica prikazuje rezultate *predtesta* za provjeru znanja kod druge *kontrolne (G4)* grupe ispitanika. Svako pitanje nosi jedan bod, što čini ukupan broja bodova 30. Prosječna vrijednost bodova koje je grupa sakupila iznosi 13,36 uz standardnu devijaciju od 2,87. Najčešći iznos (Mod) sakupljenih bodova je 15. Raspon bodova koji su ispitanici ostvarili iznosi od 7 do 19.

Tablica P.34. Rezultati *predtesta* za **treću kontrolnu (G6)** grupu ispitanika (N =14)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	15,71	3,71	17	9-22

Rezultati *predtesta* za provjeru znanja kod treće *kontrolne (G6)* grupe ispitanika, prikazani su u tablici P.34. Prosječna vrijednost bodova koju je grupa postigla iznosi 15,71 uz standardnu devijaciju od 3,71. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 17. Raspon bodova kreće se od minimalno 9 do maksimalno 22.

Tablica P.35. Rezultati *predtesta* za **četvrtu kontrolnu (G8)** grupu ispitanika (N =15)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	14,93	4,27	19	7-20

Tablica prikazuje rezultate *predtesta* za provjeru znanja kod četvrte *kontrolne (G8)* grupe ispitanika. Od ukupnog broja bodova, četvrta eksperimentalna grupa ostvarila je prosječnu

vrijednost bodova u iznosu od 14,93 uz standardnu devijaciju od 4,27. Najčešći iznos (Mod) sakupljenih bodova iznosi 19. Raspon bodova koji su ispitanici ostvarili iznosi od 7 do 20.

Tablica P.36. Rezultati *predtesta* za **petu kontrolnu (G9)** grupu ispitanika (N =15)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	14,60	4,44	14	9-23

Tablica prikazuje rezultate *predtesta* za provjeru znanja kod pete *kontrolne (G9)* grupe ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 14,60 uz standardnu devijaciju od 4,44. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 14. Raspon bodova kreće se od minimalno 9 do maksimalno 23. Ukupan broj mogućih bodova iznosi 30.

Tablica P.37. Rezultati *predtesta* za **šestu kontrolnu (G10)** grupu ispitanika (N=15)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	15,33	2,97	17	8-20

Tablica prikazuje rezultate *predtesta* za provjeru znanja kod šeste *kontrolne (G10)* grupe ispitanika. Svako pitanje nosi jedan bod, što čini ukupan broja bodova 30. Prosječna vrijednost bodova koje je grupa sakupila iznosi 15,33 uz standardnu devijaciju od 2,97. Najčešći iznos (Mod) sakupljenih bodova je 17. Raspon bodova koji su ispitanici ostvarili iznosi od 8 do 20.

Tablica P.38. Rezultati *predtesta* za **sedmu kontrolnu (G13)** grupu ispitanika (N =14)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	15,64	3,97	14	9-21

Tablica P.38. prikazuje rezultate *predtesta* za provjeru znanja kod sedme *kontrolne (G13)* grupe ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 15,64 uz standardnu devijaciju od 3,97. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 14. Raspon bodova kreće se od minimalno 9 do maksimalno 21. Ukupan broj mogućih bodova iznosi 30.

Posttest analiza rezultata u provedenom prvom glavnom istraživanju

U ovom prilogu nalazi se analiza prosječnih rezultata *posttesta* iz provedenog *prvog glavnog istraživanja* koje je prikazano u poglavlju 6.2.2.

Tablica P.39. Rezultati *posttesta* za **prvu eksperimentalnu (G2)** grupu ispitanika (N =14)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	11,86	6,20	8	6-23

Tablica prikazuje rezultate *posttesta* za provjeru znanja kod prve *eksperimentalne (G2)* grupe ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 11,86 uz standardnu devijaciju od 6,20. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 8. Raspon bodova kreće se od minimalno 6 do maksimalno 23. Ukupan broj mogućih bodova iznosi 30.

Tablica P.40. Rezultati *posttesta* za **drugu eksperimentalnu (G3)** grupu ispitanika (N=14)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	15,71	5,70	17	7-23

Tablica prikazuje rezultate *posttesta* za provjeru znanja kod druge *eksperimentalne (G3)* grupe ispitanika. Svako pitanje nosi jedan bod, što čini ukupan broja bodova 30. Prosječna vrijednost bodova koje je grupa sakupila iznosi 15,71 uz standardnu devijaciju od 5,70. Najčešći iznos (Mod) sakupljenih bodova je 17. Raspon bodova koji su ispitanici ostvarili iznosi od 7 do 23.

Tablica P.41. Rezultati *posttesta* za **treću eksperimentalnu (G5)** grupu ispitanika (N =15)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	13,73	3,63	12	9-20

Rezultati *posttesta* za provjeru znanja kod treće *eksperimentalne (G5)* grupe ispitanika, prikazani su u tablici P.41. Prosječna vrijednost bodova koju je grupa postigla iznosi 13,73 uz standardnu devijaciju od 3,63. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 12. Raspon bodova kreće se od minimalno 9 do maksimalno 20.

Tablica P.42. Rezultati *posttesta* za četvrtu *eksperimentalnu* (G7) grupu ispitanika (N =12)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	12,58	4,48	10	8-21

Tablica prikazuje rezultate *posttesta* za provjeru znanja kod četvrte *eksperimentalne* (G7) grupe ispitanika. Od ukupnog broja bodova, četvrta eksperimentalna grupa ostvarila je prosječnu vrijednost bodova u iznosu od 12,58 uz standardnu devijaciju od 4,48. Najčešći iznos (Mod) sakupljenih bodova iznosi 10. Raspon bodova koji su ispitanici ostvarili iznosi od 8 do 21.

Tablica P.43. Rezultati *posttesta* za petu *eksperimentalnu* (G11) grupu ispitanika (N =12)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	14,00	5,17	12	7-23

Tablica prikazuje rezultate *posttesta* za provjeru znanja kod pete *eksperimentalne* (G11) grupe ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 14,00 uz standardnu devijaciju od 5,17. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 12. Raspon bodova kreće se od minimalno 7 do maksimalno 23. Ukupan broj mogućih bodova iznosi 30.

Tablica P.44. Rezultati *posttesta* za šestu *eksperimentalnu* (G12) grupu ispitanika (N=15)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	16,73	6,47	14	7-27

Tablica prikazuje rezultate *posttesta* za provjeru znanja kod šeste *eksperimentalne* (G12) grupe ispitanika. Svako pitanje nosi jedan bod, što čini ukupan broja bodova 30. Prosječna vrijednost bodova koje je grupa sakupila iznosi 16,73 uz standardnu devijaciju od 6,47. Najčešći iznos (Mod) sakupljenih bodova je 14. Raspon bodova koji su ispitanici ostvarili iznosi od 7 do 27.

Tablica P.45. Rezultati *posttesta* za sedmu *eksperimentalnu* (G14) grupu ispitanika (N =14)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	12,21	4,74	15	5-21

Rezultati *posttesta* za provjeru znanja kod sedme *eksperimentalne* (G14) grupe ispitanika, prikazani su u tablici P.45. Prosječna vrijednost bodova koju je grupa postigla iznosi 12,21 uz standardnu devijaciju od 4,74. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 15. Raspon bodova kreće se od minimalno 5 do maksimalno 21.

Tablica P.46. Rezultati *posttesta* za **prvu kontrolnu (G1)** grupu ispitanika (N =15)

Broj pitanja N	Prosječna vrijednost M	Standardna devijacija σ	Mod	Raspon vrijednosti min-max
30	12,40	3,40	12	8-21

Tablica P.46. prikazuje rezultate *posttesta* za provjeru znanja kod prve *kontrolne (G1)* grupe ispitanika. Od ukupnog broja bodova, prva kontrolna grupa ostvarila je prosječnu vrijednost bodova u iznosu od 12,40 uz standardnu devijaciju od 3,40. Najčešći iznos (Mod) sakupljenih bodova iznosi 12. Raspon bodova koji su ispitanici ostvarili iznosi od 8 do 21.

Tablica P.47. Rezultati *posttesta* za **drugu kontrolnu (G4)** grupu ispitanika (N=13)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	12,77	4,66	11	5-21

Tablica prikazuje rezultate *posttesta* za provjeru znanja kod druge *kontrolne (G4)* grupe ispitanika. Svako pitanje nosi jedan bod, što čini ukupan broja bodova 30. Prosječna vrijednost bodova koje je grupa sakupila iznosi 12,77 uz standardnu devijaciju od 4,66. Najčešći iznos (Mod) sakupljenih bodova je 11. Raspon bodova koji su ispitanici ostvarili iznosi od 5 do 21.

Tablica P.48. Rezultati *posttesta* za **treću kontrolnu (G6)** grupu ispitanika (N =13)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	11,00	3,92	11	6-19

Rezultati *posttesta* za provjeru znanja kod treće *kontrolne (G6)* grupe ispitanika, prikazani su u tablici P.48. Prosječna vrijednost bodova koju je grupa postigla iznosi 11,00 uz standardnu devijaciju od 3,92. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 11. Raspon bodova kreće se od minimalno 6 do maksimalno 19.

Tablica P.49. Rezultati *posttesta* za **četvrtu kontrolnu (G8)** grupu ispitanika (N =14)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	13,07	2,53	12	10-18

Tablica prikazuje rezultate *posttesta* za provjeru znanja kod četvrte *kontrolne (G8)* grupe ispitanika. Od ukupnog broja bodova, četvrta *kontrolne* grupa ostvarila je prosječnu vrijednost bodova u iznosu od 13,07 uz standardnu devijaciju od 2,53. Najčešći iznos (Mod) sakupljenih bodova iznosi 12. Raspon bodova koji su ispitanici ostvarili iznosi od 10 do 18.

Tablica P.50. Rezultati *posttesta* za **petu kontrolnu (G9)** grupu ispitanika (N =15)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	12,33	4,85	10	6-23

Tablica prikazuje rezultate *posttesta* za provjeru znanja kod *pete kontrolne (G9)* grupe ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 12,33 uz standardnu devijaciju od 4,85. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 10. Raspon bodova kreće se od minimalno 6 do maksimalno 23. Ukupan broj mogućih bodova iznosi 30.

Tablica P.51. Rezultati *posttesta* za **šestu kontrolnu (G10)** grupu ispitanika (N=13)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	11,46	4,86	6	6-22

Tablica prikazuje rezultate *posttesta* za provjeru znanja kod *šeste kontrolne (G10)* grupe ispitanika. Svako pitanje nosi jedan bod, što čini ukupan broja bodova 30. Prosječna vrijednost bodova koje je grupa sakupila iznosi 11,46 uz standardnu devijaciju od 4,86. Najčešći iznos (Mod) sakupljenih bodova je 6. Raspon bodova koji su ispitanici ostvarili iznosi od 6 do 22.

Tablica P.52. Rezultati *posttesta* za **sedmu kontrolnu (G13)** grupu ispitanika (N =13)

Broj pitanja	Prosječna vrijednost bodova M	Standardna devijacija σ	Mod	Raspon vrijednosti bodova min-max
30	11,00	4,10	7	4-18

Tablica P.52. prikazuje rezultate *posttesta* za provjeru znanja kod *sedme kontrolne (G13)* grupe ispitanika. Prosječna vrijednost bodova koju je grupa postigla iznosi 11,00 uz standardnu devijaciju od 4,10. Najčešća vrijednost (Mod) ostvarenih bodova iznosi 7. Raspon bodova kreće se od minimalno 4 do maksimalno 18. Ukupan broj mogućih bodova iznosi 30.

Rezultat analize unutarnje konzistentnosti skala u prvom glavnom istraživanju

S obzirom na odnos između čestica u skali i dobivenog koeficijenta unutarnje konzistentnosti (CA) za sve skale korištene u *prvom glavnom istraživanju* navode se tablice (od P.53. do P.66.) analiza unutarnjih konzistentnosti skala.

Tablica P.53. Skala: *Zadovoljstvo korištenja e-tečaja* (CA = ,858)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
ZAD_1	,679	,835
ZAD_2R	,337	,867
ZAD_3	,541	,847
ZAD_4R	,492	,853
ZAD_5	,694	,832
ZAD_6	,690	,833
ZAD_7R	,734	,828
ZAD_8	,601	,842
ZAD_9R	,519	,849

Tablica P.54. Skala: *Pregled nad tečajem / navigacija* (CA = ,903)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
NAV_1	,664	,893
NAV_2	,568	,899
NAV_3	,594	,897
NAV_4	,723	,890
NAV_5R	,555	,899
NAV_7	,637	,895
NAV_8	,770	,887
NAV_9R	,618	,896
NAV_12	,684	,893
NAV_13R	,675	,893
NAV_14R	,598	,897

Statistički izračun i logički smisao pitanja uključeni su u analizu čestica svake skale iz provedenog *anketnog upitnika*. U skali *Zadovoljstvo korištenja e-tečaja* nije evidentirana niti jedna čestica koja bi trebala biti korigirana niti je brisana iz provedenog *anketnog upitnika*. Skala pod nazivom *Pregled nad tečajem / navigacija* sadrži čestice nisu korigirane niti mijenjane na bilo koji način, te se prenose u *anketni upitnik drugog glavnog istraživanja*.

Tablica P.55. Skala: Povratne informacije u e-tečaju (CA = ,904)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
FDB_1	,756	,886
FDB_2	,788	,875
FDB_3	,782	,876
FDB_4	,814	,864

Tablica P.56. Skala: Zaokupljenost / uživljanje (CA = ,841)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
UZI_1	,634	,820
UZI_2R	,096	,856
UZI_3	,723	,815
UZI_4	,682	,817
UZI_5R	,363	,840
UZI_6	,311	,842
UZI_7	,594	,823
UZI_9	,567	,825
UZI_10	,710	,815
UZI_12R	,231	,847
UZI_13	,621	,821
UZI_14	,463	,832
UZI_15R	,472	,832

Tablica P.57. Skala: Priprema / uputa za rad s e-tečajem (CA = ,739)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
UPT_2	,620	,673
UPT_3	,545	,686
UPT_5R	,209	,767
UPT_6R	,390	,723
UPT_7	,343	,735
UPT_8	,592	,678
UPT_9	,551	,686

U skalama *Povratne informacije u e-tečaju* nije potrebno mijenjati niti jednu česticu. Unutar skala *Zaokupljenost / uživljanje* i *Priprema / uputa za rad s e-tečajem* prikazane su čestice koje se trebaju obrisati (**UZI_2R** i **UPT_5R**), dok se ostale prenose u *anketni upitnik drugog glavnog istraživanja*.

Tablica P.58. Skala: Primjerena težina e-tečaja (CA = ,770)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
TEZ_1	,527	,737
TEZ_2	,615	,722
TEZ_3R	,570	,727
TEZ_4R	,532	,735
TEZ_5	,285	,782
TEZ_6	,385	,760
TEZ_7R	,450	,749
TEZ_8	,442	,750

Tablica P.59. Skala: Motivacijski poticaji (CA = ,835)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
POT_1	,550	,841
POT_3	,792	,736
POT_4	,629	,808
POT_5	,710	,773

Tablica P.60. Skala: Agregacija elemenata za motivacijske poticaje (CA = ,949)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
GEM_1	,650	,947
GEM_2	,691	,946
GEM_3	,576	,948
GEM_4	,581	,948
GEM_5	,714	,946
GEM_6	,552	,948
GEM_7	,497	,949
GEM_8	,599	,948
GEM_9	,721	,946
GEM_10	,789	,944
GEM_11	,828	,944
GEM_12	,822	,944
GEM_13	,787	,944
GEM_14	,687	,946
GEM_15	,600	,948
GEM_16	,777	,944
GEM_17	,811	,944
GEM_18	,805	,944

Tablica P.61 Skala: **Interakcija unutar e-tečaja** (CA = ,885)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
INT_1	,722	,866
INT_2	,670	,871
INT_3	,715	,867
INT_4	,734	,866
INT_5	,753	,865
INT_6	,712	,868
INT_7	,588	,876
INT_8	,722	,866
INT_9	,714	,867
<u>INT_11R</u>	<u>-.074</u>	<u>.919</u>

Tablica P.62. Skala: **Postignuće učenja** (CA = ,867)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
POS_1	,639	,850
POS_2	,679	,846
POS_3	,521	,861
POS_4	,700	,843
POS_5	,590	,854
POS_6	,556	,857
POS_7	,529	,860
POS_8	,554	,858
POS_9	,638	,850

Tablica P.63. Skala: **Individualni proces učenja** (CA = ,859)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
IND_1	,623	,840
IND_2	,630	,839
IND_3	,590	,845
IND_4	,562	,848
IND_5	,736	,823
IND_6	,722	,825
IND_7	,539	,853

U skali pod nazivom *Primjerena težina e-tečaja* obrisana je jedna čestica (**TEZ_5**), dok ostale nisu mijenjane. U skali pod nazivom *Interakcija unutar e-tečaja* obrisana je jedna čestica s negativnim predznakom (**INT_11R**) dok ostale čestice nisu mijenjane.

Tablica P.64. Skala: Doživljaj e-tečaja (CA = ,778)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
DOZ_1R	,407	,764
DOZ_2	,409	,763
DOZ_3	,548	,747
DOZ_5	,504	,751
DOZ_6R	,115	,810
DOZ_7	,523	,748
DOZ_8	,531	,749
DOZ_9R	,376	,768
DOZ_10	,585	,745
DOZ_11	,610	,738

Tablica P.65. Skala: Evaluacija e-tečaja (CA = ,931; za čestice od 1 do 15)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
EVA_1	,499	,930
EVA_2	,366	,931
EVA_3	,521	,929
EVA_4	,550	,929
EVA_5	,523	,929
EVA_6	,684	,927
EVA_7	,766	,926
EVA_8R	,340	,932
EVA_9	,552	,929
EVA_10	,388	,931
EVA_11	,696	,927
EVA_12	,696	,927
EVA_13	,602	,928
EVA_14	,666	,927
EVA_15	,614	,928

Unutar skale pod nazivom *Doživljaj e-tečaja*, jedna čestica je obrisana (**DOZ_6R**), dok ostale čestice nisu mijenjane i spremne su za korištenje unutar *anketnog upitnika drugog glavnog istraživanja*. Skala pod nazivom *Evaluacija e-tečaja* podijeljena je na dva dijela zbog velikog broja čestica. Ostatak skale pod nazivom *Evaluacija e-tečaja* nalazi se u nastavku rada.

Tablica P.66. Skala: **Evaluacija e-tečaja** ($CA = ,931$; za čestice od 17 do 28)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
EVA_17	,482	,930
EVA_18	,645	,928
EVA_19R	,278	,932
EVA_20R	,401	,931
EVA_21	,457	,930
EVA_22	,640	,928
EVA_23	,730	,926
EVA_24R	,367	,932
EVA_25	,658	,928
EVA_27	,705	,927
EVA_28	,653	,928
EVA_29	,586	,929
EVA_30R	,409	,931

U drugom dijelu skale pod nazivom *Evaluacija e-tečaja* nije potrebno mijenjati niti jednu česticu. Slijedi analiza rezultata *eksperimentalne* i *kontrolne* grupe u provedenom *prvom glavnom istraživanju* s obzirom na **korigirane skale** i **njihove čestice**. Analiza skala **druge cjeline anketnog upitnika** nakon isključivanja neodgovarajućih čestica prikazana je u tablici P.67.

Tablica P.67. Analiza skala **druge cjeline** *anketnog upitnika* u provedenom *prvom glavnom istraživanju* nakon isključivanja neodgovarajućih čestica iz skala (N=182)

Naziv skale	Broj čestica	Prosječna vrijednost	Standardna devijacija σ	Raspon odgovora	Cronbach alpha koef.
Zadovoljstvo korištenja e-tečaja	9	2,95	1,10	1-5	,858
Pregled nad tečajem / navigacija	11	3,14	1,21	1-5	,903
Povratne informacije u e-tečaju	4	3,41	1,16	1-5	,904
Zaokupljenost / uživanje	12	2,81	1,10	1-5	,856
Priprema / uputa za rad s e-tečajem	6	3,36	1,16	1-5	,767
Primjerna težina e-tečaja	7	3,13	1,17	1-5	,782
Motivacijski poticaji	4	3,27	1,03	1-5	,835
Agregacija elemenata za motivacijske poticaje	18	4,19	1,91	1-7	,949
Interakcija unutar e-tečaja	9	3,02	1,12	1-5	,919
Postignuće učenja	9	3,48	0,94	1-5	,867
Individualni proces učenja	7	3,64	1,06	1-5	,859
Doživljaj e-tečaja	9	3,31	1,11	1-5	,810
Evaluacija e-tečaja	28	3,29	1,12	1-5	,931

PRILOG 7. ANALIZA REZULTATA OBRADJE PODATAKA U PROVEDENOM DRUGOM GLAVNOM ISTRAŽIVANJU

U ovom prilogu nalazi se analiza **unutarnje konzistentnosti skala** iz provedenog *drugog glavnog istraživanja* koje je prikazano u poglavlju 6.3.

Rezultat analize unutarnje konzistentnosti skala u drugom glavnom istraživanju

S obzirom na odnos između čestica u skali i dobivenog koeficijenta unutarnje konzistentnosti (CA) za sve skale korištene u *drugom glavnom istraživanju* navode se tablice (P.68. do P.81.) analiza unutarnjih konzistentnosti skala.

Tablica P.68. Skala: **Zadovoljstvo korištenja e-tečaja** (CA = ,852)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
ZAD_1	,560	,838
ZAD_2R	,420	,852
ZAD_3	,467	,846
ZAD_4R	,225	,870
ZAD_5	,734	,820
ZAD_6	,776	,815
ZAD_7R	,776	,812
ZAD_8	,702	,822
ZAD_9R	,536	,840

Tablica P.69. Skala: **Pregled nad tečajem / navigacija** (CA = ,912)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
NAV_1	,688	,902
NAV_2	,664	,903
NAV_3	,657	,904
NAV_4	,705	,902
NAV_5R	,755	,899
NAV_7	,526	,910
NAV_8	,692	,902
NAV_9R	,523	,913
NAV_12	,676	,904
NAV_13R	,719	,901
NAV_14R	,742	,899

U skali *Zadovoljstvo korištenja e-tečaja* nije evidentirana niti jedna čestica koja bi trebala biti korigirana niti je brisana iz provedenog *anketnog upitnika*. Skala pod nazivom *Pregled nad tečajem / navigacija* sadrži čestice nisu korigirane niti mijenjane na bilo koji način.

Tablica P.70. Skala: **Povratne informacije u e-tečaju** (CA = ,912)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
FDB_1	,828	,877
FDB_2	,800	,887
FDB_3	,761	,900
FDB_4	,816	,881

Tablica P.71. Skala: **Zaokupljenost / uživanje** (CA = ,835)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
UZI_1	,750	,800
UZI_3	,688	,807
UZI_4	,722	,805
UZI_5R	,388	,833
UZI_6	,210	,843
UZI_7	,623	,814
UZI_9	,605	,815
UZI_10	,723	,805
<u>UZI_12R</u>	<u>-.004</u>	<u>.853</u>
UZI_13	,394	,830
UZI_14	,575	,818
UZI_15R	,338	,840

Tablica P.72. Skala: **Priprema / uputa za rad s e-tečajem** (CA = ,666)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
UPT_2	,320	,649
UPT_3	,371	,632
UPT_6R	,343	,646
<u>UPT_7</u>	<u>.194</u>	<u>.695</u>
UPT_8	,565	,554
UPT_9	,628	,534

U skali *Zaokupljenost / uživanje* i pronađena je jedna čestica (**UZI_12R**) koju bi trebalo obrisati čime bi se utjecalo na povećanje Cronbach alpha vrijednosti.

Tablica P.73. Skala: Primjerena težina e-tečaja (CA = ,650)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
TEZ_1	,301	,630
TEZ_2	,459	,581
TEZ_3R	,380	,610
TEZ_4R	,357	,621
TEZ_6	,338	,620
TEZ_7R	,387	,605
TEZ_8	,317	,626

Tablica P.74. Skala: Motivacijski poticaji (CA = ,763)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
POT_1	,592	,691
POT_3	,652	,658
POT_4	,513	,734
POT_5	,511	,743

Tablica P.75. Skala: Agregacija elemenata za motivacijske poticaje (CA = ,935)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
GEM_1	,724	,930
GEM_2	,364	,937
GEM_3	,504	,934
GEM_4	,492	,935
GEM_5	,575	,933
GEM_6	,477	,935
GEM_7	,570	,933
GEM_8	,548	,934
GEM_9	,614	,932
GEM_10	,832	,927
GEM_11	,878	,926
GEM_12	,809	,928
GEM_13	,620	,932
GEM_14	,698	,931
GEM_15	,677	,931
GEM_16	,705	,931
GEM_17	,733	,930
GEM_18	,688	,931

U skalama pod nazivom *Primjerena težina e-tečaja*, *Motivacijski poticaji* i *Agregacija elemenata za motivacijske poticaje* čestice nisu mijenjane.

Tablica P.76. Skala: **Interakcija unutar e-tečaja** ($\underline{CA} = ,894$)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
INT_1	,652	,882
INT_2	,692	,879
INT_3	,703	,878
INT_4	,613	,885
INT_5	,631	,884
INT_6	,731	,875
INT_7	,559	,889
INT_8	,617	,885
INT_9	,674	,880

Tablica P.77. Skala: **Postignuće učenja** ($\underline{CA} = ,867$)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
POS_1	,667	,846
POS_2	,555	,857
POS_3	,274	,878
POS_4	,654	,847
POS_5	,705	,842
POS_6	,681	,845
POS_7	,650	,848
POS_8	,506	,861
POS_9	,676	,845

Tablica P.78. Skala: **Individualni proces učenja** ($\underline{CA} = ,824$)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
IND_1	,455	,818
IND_2	,508	,811
IND_3	,688	,779
IND_4	,565	,803
IND_5	,690	,779
IND_6	,625	,792
IND_7	,458	,818

U skalama pod nazivom *Interakcija unutar e-tečaja*, *Postignuće učenja* i *Individualni proces učenja* čestice nisu mijenjane.

Tablica P.79. Skala: Doživljaj e-tečaja (CA = ,805)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
DOZ_1R	,442	,793
DOZ_2	,146	,824
DOZ_3	,377	,799
DOZ_5	,574	,775
DOZ_7	,562	,777
DOZ_8	,596	,772
DOZ_9R	,576	,774
DOZ_10	,684	,769
DOZ_11	,563	,778

Tablica P.80. Skala: Evaluacija e-tečaja (CA = ,943; za čestice od 1 do 15)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
EVA_1	,698	,940
EVA_2	,470	,942
EVA_3	,339	,944
EVA_4	,671	,940
EVA_5	,351	,943
EVA_6	,510	,942
EVA_7	,777	,939
EVA_8R	,186	,946
EVA_9	,686	,940
EVA_10	,520	,942
EVA_11	,885	,938
EVA_12	,550	,942
EVA_13	,756	,939
EVA_14	,752	,939
EVA_15	,764	,939

Unutar skale pod nazivom *Doživljaj e-tečaja*, jednu česticu (**DOZ_2**) je potrebno obrisati, dok ostale čestice nisu mijenjane i spremne su za buduće korištenje. Skala pod nazivom *Evaluacija e-tečaja* podijeljena je na dva dijela zbog velikog broja čestica. Ostatak skale pod nazivom *Evaluacija e-tečaja* nalazi se u nastavku rada.

Tablica P.81. Skala: **Evaluacija e-tečaja** ($CA = ,943$; za čestice od 17 do 28)

Oznaka čestice	Korigirana korelacija čestice i skale	Cronbach Alpha ako se čestica izbaci
EVA_17	,568	,941
EVA_18	,835	,938
EVA_19R	,129	,946
EVA_20R	,755	,939
EVA_21	,232	,944
EVA_22	,554	,941
EVA_23	,790	,939
EVA_24R	,136	,945
EVA_25	,693	,940
EVA_27	,754	,939
EVA_28	,787	,939
EVA_29	,648	,941
EVA_30R	,696	,940

U drugom dijelu skale pod nazivom *Evaluacija e-tečaja* čestice nisu mijenjane. Slijedi analiza rezultata *eksperimentalne* i *kontrolne* grupe u provedenom *drugom glavnom istraživanju* s obzirom na **korigirane skale** i **njihove čestice**.

DOKTORSKA DISERTACIJA

UVODENJE ELEMENATA RAČUNALNE IGRE U *ONLINE* POUČAVANJE SADRŽAJA INFORMATIČKIH NASTAVNIH PREDMETA

Andrija Bernik

Fakultet organizacije i informatike, Varaždin, Hrvatska

Sažetak: Opisano područje istraživanja naziva se gemifikacija i predstavlja korištenje elemenata računalnih igara (mehanike, dinamike i estetike) u području koje nije računalna igra. Dosadašnja istraživanja pokazuju kako je pedagoški i psihološki utjecaj korištenja elemenata računalnih igara na e-učenje pozitivan, stoga će se u ovome radu naglasak staviti na razmatranje uvođenja elemenata računalnih igara u *online* poučavanju sadržaja informatičkih predmeta.

Ovom disertacijom će se uz pomoć teorijskog i empirijskog istraživanja: 1) kreirati konceptualan model i skup preporuka za primjenu gemifikacijskog obrazovnog sustava koji utječe na veće korištenje sadržaja e-tečaja, mjereno objektivnim pokazateljima, uz naglasak na korištenje elemenata računalne igre; 2) kreirati *gemificirani* e-tečaj u području poučavanja sadržaja informatičkih predmeta; 3) ispitati mogući pozitivan učinak na ishode učenja kod *eksperimentalne* skupine studenata koji će koristiti *gemificirani* e-tečaj (*online* sustav).

Voditelji rada: prof.dr.sc. Goran Bubaš i prof.dr.sc. Danijel Radošević

Povjerenstvo za ocjenu: prof.dr.sc. Goran Bubaš, prof.dr.sc. Danijel Radošević, prof.dr.sc. Dragutin Kermek, izv. prof.dr.sc. Mihaela Banek Zorica, doc.dr.sc. Igor Balaban

Povjerenstvo za obranu: prof.dr.sc. Dragutin Kermek, izv. prof.dr.sc. Mihaela Banek Zorica, doc.dr.sc. Igor Balaban, doc.dr.sc. Dijana Plantak Vukovac (zamjenski član)

Datum obrane: 07.07.2017.

Datum promocije: rujan 2017.

Rad je pohranjen na Fakultetu organizacije i informatike Varaždin.

(415 stranica, 87 slika, 229 tablica, 56 priloga, 194 referenci, original na hrvatskom jeziku)

Andrija Bernik

ŽIVOTOPIS

Andrija Bernik rođen je 24. ožujka 1985. godine u Karlovcu. Osnovnu školu "Vladimir Nazor" završio je 1999. godine u Dugoj Resi. Srednju Tehničku školu Karlovac, smjer elektrotehničar završio je 2003. godine, kada je upisao Fakultet organizacije i informatike u Varaždinu, smjer Informacijski sustavi. Tijekom studiranja izabran je za demonstratora na kolegiju Formalne metode za informatičare. Sudjeluje na pet natjecanja u području 3D modeliranja i računalne animacije od 2007. do 2009. godine, te osvaja pet uzastopnih prvih mjesta. Dobitnik je dvije Dekanove nagrade za izvrsnost i trud u 2008. i 2009. godini. Diplomirao je 2009. godine na temu "Autodesk Maya - Izrada digitalne animacije", te dobio priznanje fakulteta jer je bio jedan od 10% studenata s najboljim prosjekom u 2009. godini.

Iste godine počinje raditi na Veleučilištu u Varaždinu, danas Sveučilištu Sjever, gdje je izabran u nastavno zvanje predavača, te je nositelj dva kolegija "3D modeliranje" na drugoj godini i "Video animacija" na trećoj godini studija Multimedija, oblikovanje i primjena gdje i danas obavlja navedene dužnosti. Od 2009. godine do trenutka pisanja ove disertacije predavač je i voditelj radionice "3D modeliranje" u Centru izvrsnosti za informatiku u Varaždinskoj županiji. Paralelno s navedenim, od 2009. godine do trenutka pisanja ove disertacije zaposlen je i u Srednjoj školi u Maruševcu s pravom javnosti, na poziciji nastavnika Informatike, te administratora e-dnevnika i računalnih resursa. Završio je program pedagoško-psihološkog obrazovanja 2010. godine na Učiteljskom fakultetu u Čakovcu, Sveučilišta u Zagrebu. Godine 2010. upisuje doktorski studij informacijskih znanosti na Fakultetu organizacije i informatike. Predavač je na 7 međunarodnih konferencija iz područja dizajna i suvremenih grafičkih tehnologija. Autor je i grafički urednik dva recenzirana sveučilišna udžbenika koji nose nazive "3D modeliranje u primjerima 1." (udžbenik broji 295 strana, te je izdan 2015. godine) i "3D modeliranje u primjerima 2." (udžbenik broji 280 strana, te je izdan 2016. godine). Oba udžbenika tiskana su u 200 primjeraka od strane Sveučilišta Sjever.

POPIS RADOVA

Udžbenici i skripta

1. Vusić, Damir; **Bernik, Andrija**; Geček, Robert.
3D modeliranje u primjerima 2. / Bernik, Andrija (ur.), Varaždin: Sveučilište Sjever, 2016.
2. Vusić, Damir; Sabati, Zvonimir; **Bernik, Andrija**.
3D modeliranje u primjerima 1. / Bernik, Andrija (ur.), Varaždin: Sveučilište Sjever, 2015.

Objavljena pozvana predavanja na skupovima

1. Sabati, Zvonimir; **Bernik, Andrija**; Žiljak Vujić, Jana.
Novi informacijski postupci za dobivanje optimalne gravure 3D modela unutar kristalnog stakla, Tiskarstvo & Dizajn 2014., Terme Tuhelj: FotoSoft 2014

Znanstveni radovi s međunarodnom recenzijom

1. **Bernik, Andrija**; Bubaš, Goran; Radošević, Danijel.
A Pilot Study of the Influence of Gamification on the Effectiveness of an e-Learning Course, Proceedings of the 26th Central European Conference on Information and Intelligent Systems (Ceciis 2015), Varaždin: Fakultet organizacije i informatike, 2015. 73-79
2. **Bernik, Andrija**; Sabati, Zvonimir; Bregović, Valentina.
Stvaranje hologramskih efekata za video u Mayi i After Effectsu, Tiskarstvo & Dizajn 2015., Zagreb: FS, FotoSoft 2015
3. Vusić, Damir; **Bernik, Andrija**; Podboj, Branimir.
Osnove mapiranja pomoću tekstura, MATRIB 2015 International Conference on Materials, Wear, Recycling, Zagreb: Croatian Society for Materials and Tribology, 2015. 370-379
4. Bačanek, Nikola; **Bernik, Andrija**; Geček, Robert.
Sinkronizacija govora u virtualnom 3D prostoru, Tiskarstvo & Dizajn 2014, Terme Tuhelj: FotoSoft 2014
5. Car, Saša; Vusić, Damir; **Bernik, Andrija**.
Usporedba CPU i GPU Renderiranja, Tiskarstvo & Dizajn 2013, Zagreb: FS, FotoSoft 2013
6. **Bernik, Andrija**; Sabati, Zvonimir.
Generating Terrain And Hi Details Using Texture Maps, Tiskarstvo & Dizajn 2013, Zagreb: FS, FotoSoft 2013

7. Sabati, Zvonimir; **Bernik, Andrija**.
Mental ray - iscrtavanje i vizualizacija računalne grafike, Digitalni sustavi u tiskarstvu, Tiskarstvo 2012, Scientific meeting printers and graphic artists of printing technology Croatian Academy of Engineering, Stubičke toplice 2012
8. Sabati, Zvonimir; **Bernik, Andrija**.
Implementacija tekstura unutar sustava za lasersko graviranje, Proceedings of 22st Central European Conference on Information and Intelligent Systems, CECIIS 2011., Varaždin: Fakultet organizacije i informatike Varaždin, 2011., 213-221
9. Sabati, Zvonimir; **Bernik, Andrija**; Prprović, Nikola.
Metode rada i odabir materijala za 3d ispis, Digitalni sustavi u tiskarstvu, Tiskarstvo 2011, Scientific meeting printers and graphic artists of printing technology Croatian Academy of Engineering, Stubičke toplice 2011
10. Sabati, Zvonimir; **Bernik, Andrija**; Radovac, Mario.
Lasersko graviranje računalnih modela, Digitalni sustavi u tiskarstvu, Tiskarstvo 2011, Scientific meeting printers and graphic artists of printing technology Croatian Academy of Engineering, Stubičke toplice 2011
11. Sabati, Zvonimir; **Bernik, Andrija**; Ratković, Adela; Dolenc, Stjepan.
Ray tracing algoritam renderiranja, Proceedings of 22st Central European Conference on Information and Intelligent Systems, CECIIS 2011., Varaždin: Fakultet organizacije i informatike Varaždin, 2011., 221-227
12. Sabati, Zvonimir; Bernik, Andrija; Jovanovska, Dora.
3D modelling functions and algorithms, Proceedings of 21st Central European Conference on Information and Intelligent Systems, CECIIS 2010., Varaždin: Fakultet organizacije i informatike Varaždin, 2010. 327-334
13. Zvonimir, Sabati; Zlatan, Novak; **Andrija, Bernik**.
Standardization of 3d models creation procedures in computer graphics, 11th International Design Conference - Design 2010, Zagreb: Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb, 2010. 1869-1874

Stručni radovi

1. **Bernik, Andrija;** Hatlak, Dorja.
Autodesk Maya – Maya paint efekti, Polytechnic and design 4 (2016), 2; 131-144
2. Dijanić, Dorijan; **Bernik, Andrija.**
Proces iscertavanja: usporedba 3ds max, cinema 4d i maye, Polytechnic and design 4 (2016), 2; 117-129
3. **Bernik, Andrija;** Sabati, Zvonimir; Ladić, Mihael.
Pokreti i animacija u Solidworksu, Polytechnic and Design 2 (2014), 2; 212- 221
4. Čovran, Krunoslav; **Bernik, Andrija;** Vusić, Damir.
Autodesk Maya - Dinamična polja u računalnoj animaciji, Tehnički glasnik. 8 (2014); 102-108
5. Vusić, Damir; **Bernik, Andrija;** Rohtek, Dubravko.
Autodesk Maya - Maya Paint efekti, Tehnički glasnik. 8 (2014), 4; 394-404
6. Blažuc, Goran; **Bernik, Andrija.**
Tehnike renderiranja i računalnog osvjetljenja, Tehnički glasnik. 7 (2013), 3; 273-282
7. Ribar, Aleksandar; **Bernik, Andrija;** Vusić, Damir.
Komponiranje 3D rendera u živu snimku, Tehnički glasnik 7 (2013), 1; 64-71
8. Turkalj, Robert; **Bernik, Andrija;** Vusić, Damir.
nCloth sustav za simuliranje tkanina, Tehnički glasnik 7 (2013), 2; 162-169
9. **Bernik, Andrija;** Stipetić, Ilija.
Laserske zrake u strojnoj industriji, Tehnički Glasnik 5 (2011); 5-9
10. **Bernik, Andrija.**
Vrste i tehnike 3d modeliranja, Tehnički Glasnik 4 (2010); 45-47