

Zahvaljujem mentoru prof. dr. sc. Tihomiru Hunjaku i sumentorici prof.dr.sc. Blaženki Divjak na povjerenju, poticaju i uloženom trudu tijekom izrade ove doktorske disertacije.

Zahvaljujem im na znanstvenom i stručnom usmjeravanju te na podršci, pomoći, sugestijama i vođenju u izradi ovog rada.

Zahvaljujem profesoru Thomasu Saatyu i njegovoj supruzi Rozann Whitaker Saaty na podršci i nesebičnom prijenosu znanja i iskustva tijekom mog boravka i rada na Katz Graduate School of Business, University of Pittsburgh, SAD.

Posebno zahvaljujem roditeljima i sestri koji su mi uvijek pružali podršku tijekom moga školovanja i svakodnevno me motivirali za rad.

Zahvaljujem im na strpljenju, razumijevanju i ljubavi.

Najtoplije zahvaljujem prijateljima te kolegama i kolegicama na prijateljstvu, korisnim savjetima i podršci tijekom izrade doktorske disertacije.

**SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE**

NINA BEGIČEVIĆ

**VIŠEKRITERIJSKI MODELI ODLUČIVANJA U STRATEŠKOM
PLANIRANJU UVOĐENJA E-UČENJA**

DOKTORSKA DISERTACIJA

VARAŽDIN, 2008.

PODACI O DISERTACIJI

I. AUTOR

Ime i prezime	NINA BEGIČEVIĆ
Datum i mjesto rođenja	12.03.1980., Varaždin
Naziv fakulteta odnosno ustanove i datum diplomiranja na VII/I stupnju	Fakultet organizacije i informatike Varaždin
Sadašnje zaposlenje	Fakultet organizacije i informatike Varaždin

II. DISERTACIJA

Naslov	VIŠEKRITERIJSKI MODELI ODLUČIVANJA U STRATEŠKOM PLANIRANJU UVOĐENJA E-UČENJA
Broj stranica, slika, tablica, priloga, bibliografskih podataka	stranica 228, slika 77, tablica 47, priloga 8, bibliografskih podataka 175
Znanstvena disciplina iz koje je postignut akademski naslov doktora znanosti	Informacijske znanosti
Fakultet na kojem je obranjena disertacija	Fakultet organizacije i informatike Varaždin

III. OCJENA I OBRANA

Datum prijave teme	12. lipanj 2007.
Datum predaje rada	14. listopad 2008.
Datum sjednice vijeća na kojem je rad prihvaćen	2. prosinac 2008.
Sastav povjerenstva koje je rad ocijenilo	Prof.dr.sc. Tihomir Hunjak Prof.dr.sc. Blaženka Divjak Prof.dr.sc. Neven Vrček Prof.dr.sc. Zoran Babić
Datum obrane rada	17. prosinac 2008.
Sastav povjerenstva pred kojim je rad obranjen	Prof.dr.sc. Tihomir Hunjak Prof.dr.sc. Blaženka Divjak Prof.dr.sc. Neven Vrček Prof.dr.sc. Zoran Babić Prof.dr.sc. Neven Brumec
Datum promocije	13. rujan 2009.

Predgovor

Implementacija e-učenja jedan je od načina primjene suvremene informacijske tehnologije kojim se ostvaruje podizanje kvalitete visokog školstva. Pomak visokoškolskih institucija prema e-učenju treba biti sastavni dio strateškog planiranja kojim se nastoji promijeniti i unaprijediti sveučilišno djelovanje.

U visokom školstvu u Hrvatskoj trenutno postoji velika potreba za strateškim planiranjem i donošenjem odluka u procesu uvođenja e-učenja u visoko školstvo. Visokoškolske institucije su u fazi donošenja strategija uvođenja e-učenja, te je istraživanje, čiji rezultati imaju primjenu u izradi strategije i razvoju modela za donošenje odluka o uvođenju e-učenja, vrijedan doprinos integraciji e-učenja na sveučilišta i fakultete.

Istraživanje je dio projekta «*Razvoj matematičkih modela za unaprjeđenje kvalitete usluga u javnom sektoru*» broj (016-0161217-0769), kojeg je koncipirao glavni istraživač prof.dr.sc. Tihomir Hunjak. Projekt je odobren i financiran od strane Ministarstva znanosti, obrazovanja i športa. Autorica radnje je prijavljena na navedenom projektu u statusu znanstvene novakinje te je u sklopu istog izradila doktorsku disertaciju.

U okviru prvog poglavlja doktorske disertacije opisani su motivi odabira teme, definiran je i opisan problem istraživanja te su navedeni ciljevi i podciljevi istraživanja te zadane hipoteze.

U drugom poglavlju objašnjena je važnost sustavne primjene e-učenja u institucijama visokog školstva. Analiza internih prednosti i slabosti te eksternih povoljnih prilika i prijetnji e-učenja izvedena je u okviru SWOT analize. U ovom poglavlju opisani su i problemi i izazovi uvođenja e-učenja na različitim razinama u visokom školstvu te navedene i neke od postojećih preporuka za rješavanje tih problema i izazova.

Treće poglavlje govori o strateškom pristupu i donošenju odluke o uvođenju e-učenja u visoko školstvo. Naglašava se važnost strateškog pristupa u postupku uvođenja e-učenja na institucije visokog školstva te se daje pregled dosadašnjih istraživanja u tom području. Nadalje, daje se uvid u

trenutačno stanje u visokom školstvu vezano uz primjenu e-učenja i dosadašnji „*bottom-up*“ pristup primjenjivan u postupku uvođenja e-učenja u institucije visokog školstva. U Hrvatskoj su prvi pomaci prema strateškom pristupu napravljeni u okviru Tempus projekta EQIBELT te su ciljevi i rezultati tog projekta također navedeni i analizirani. U procesu strateškog planiranja i donošenja odluke o uvođenju e-učenja objašnjene su četiri osnovne faze: (1) faza istraživanja problema, (2) faza razvijanja i izgradnje modela, (3) faza donošenja odluka i (4) faza provođenja odluke.

U četvrtom poglavlju opisani su ciljevi istraživanja i metode istraživanja koje su se koristile za prikupljanje i obradu podataka. Objašnjena je metoda ankete, složeni postupak kreiranja ankete koji je obuhvatio kvalitativnu analizu primjera strategija e-učenja vodećih europskih sveučilišta i fakulteta te su navedeni i opisani kriteriji za odabir ispitanika u istraživanju. Za analizu prikupljenih podataka koristila se deskriptivna statistika, faktorska analiza i klasteriranje metodom k srednjih vrijednosti. Objašnjenje navedenih metoda te pregled i interpretacija dobivenih rezultata sastavni su dijelovi ovog poglavlja.

U petom poglavlju opisani su metodološki i matematički temelji AHP metode. Navode se prednosti i nedostaci AHP metode te se daje uvid u najpoznatiju računalnu podršku AHP metodi – programski alat *Expert Choice*. U drugom djelu petog poglavlja prikazuje se proces razvoja AHP modela za donošenje odluke o uvođenju e-učenja na razini određene katedre ili kolegija. Testiranje modela izvršeno je grupnim odlučivanjem o obliku uvođenja e-učenja na kolegij Matematika, na Katedri za kvantitativne metode, na Fakultetu organizacije i informatike.

Šesto poglavlje „Analitički mrežni proces“ sadržava metodološki i matematički opis ANP metode. Postoje određene razlike između AHP i ANP metode, pa je objašnjeno i argumentirano zašto se ANP metoda smatra nadogradnjom AHP metode. Nadalje, napravljena je analiza mogućnosti njene primjene u rješavanju određenih problema te je razvijen ANP model za donošenje odluke o uvođenju e-učenja u visoko školstvo. ANP model je razvijen uz potporu alata *Super Decisions*, a testiranje modela je proveo ekspert domene na strateškom problemu odlučivanja o uvođenju e-učenja na visokoškolsku instituciju.

U sedmom poglavlju prikazani su rezultati kvalitativne analize Strategije e-učenja na Sveučilištu u Zagrebu i Strategije za e-učenje Fakulteta organizacije i informatike. Provedenom analizom utvrđen je doprinos rezultata istraživanja kreiranju Strategije e-učenja Sveučilišta u Zagrebu i Strategije za e-učenje Fakulteta organizacije i informatike. Kvalitativna analiza je obuhvatila sljedeće faze: organizaciju i pripremu podataka za analizu, pregled podataka, proces kodiranja, opisivanje kategorija ili tema za analize, način reprezentiranja opisa i tema i interpretaciju podataka.

Na kraju rada su navedeni zaključci koji su proizašli iz dobivenih rezultata istraživanja. Prikazana je kratka sinteza rada te su naznačeni daljnji mogući smjerovi istraživanja. Pregled korištene literature nalazi se također na kraju rada, a priložene su i radne tablice korištene u analizama te biografija autora.

Sadržaj

PREDGOVOR.....	I
SADRŽAJ.....	IV
Popis slika.....	VII
Popis tablica.....	XI
1. UVOD.....	1
1.1. Opis problema istraživanja.....	2
1.2. Hipoteze i ciljevi istraživanja.....	7
2. E-UČENJE U VISOKOM ŠKOLSTVU.....	9
2.1. Definicija i važnost e-učenja.....	9
2.2. Problemi i izazovi uvođenja e-učenja u visoko školstvo.....	15
2.3. Pregled važnijih istraživanja o strateškom pristupu u uvođenju e-učenja u visoko školstvo.....	17
3. STRATEŠKI PRISTUP I DONOŠENJE ODLUKE O UVOĐENJU E-UČENJA U VISOKO ŠKOLSTVO.....	21
3.1. Strateški pristup u uvođenju e-učenja u visoko školstvo.....	22
3.1.1. Važnost strateškog pristupa u uvođenju e-učenja u visoko školstvo.....	24
3.1.2. Stanje e-učenja u visokom školstvu u Hrvatskoj.....	27
3.2. Faze strateškog planiranja i donošenja odluke o uvođenju e-učenja.....	35
3.2.1. Faza istraživanja problema.....	38
3.2.2. Faza razvijanja i izgradnje modela.....	39
3.2.3. Faza donošenja odluka.....	41
3.2.4. Faza provođenja.....	43
4. ISTRAŽIVANJE.....	45
4.1. Ciljevi istraživanja.....	45
4.2. Metode istraživanja.....	46
4.2.1. Anketa.....	48
4.2.2. Deskriptivna statistika.....	49
4.2.3. Faktorska analiza.....	52
4.2.4. Klasteriranje metodom k srednjih vrijednosti.....	53

4.3. Prikupljanje podataka za istraživanje.....	56
4.3.1. Kreiranje ankete.....	57
4.3.2. Ispitanici u istraživanju.....	63
4.4. Rezultati obrade prikupljenih podataka.....	67
4.4.1. Rezultati statističke obrade.....	68
4.4.2. Rezultati faktorske analize.....	82
4.4.3. Rezultati klasteriranja metodom k srednjih vrijednosti.....	90
5. ANALITIČKI HIJERARHIJSKI PROCES (AHP METODA).....	98
5.1. Temelji AHP metode.....	98
5.1.1. Metodološki temelj AHP metode.....	99
5.1.2. Matematički temelj AHP metode.....	104
5.1.2.1. Matematička svojstva AHP metode.....	107
5.1.2.2. Konzistentnost donositelja odluke.....	111
5.1.3. Prednosti i nedostaci AHP metode.....	113
5.1.4. Pregled primjena AHP metode.....	116
5.2. AHP model za donošenje odluke o uvođenju e-učenja u visoko školstvo.....	121
5.2.1. Razvoj hijerarhijskog modela problema odlučivanja.....	121
5.2.2. Grupno odlučivanje AHP metodom uz potporu alata TeamEC2000.....	129
5.2.3. Grupno odlučivanje o obliku uvođenja e-učenja na kolegij Matematika.....	134
5.2.3.1. Izbor sudionika procesa odlučivanja.....	134
5.2.3.2. Rezultati grupnog odlučivanja.....	137
6. ANALITIČKI MREŽNI PROCES (ANP METODA).....	164
6.1. Temelji ANP metode.....	164
6.1.1. Metodološki temelj ANP metode.....	164
6.1.2. Matematički temelj ANP metode.....	174
6.1.2.1. Razlika između AHP i ANP metode.....	180
6.1.3. Pregled primjena ANP metode.....	182
6.2. ANP model za donošenje odluke o uvođenju e-učenja u visoko školstvo.....	186
6.2.1. Razvoj ANP modela odlučivanja.....	186
6.2.2. Odlučivanje ANP metodom uz potporu alata SuperDecisions.....	191

6.2.3. Odlučivanje o uvođenju e-učenja na visokoškolsku instituciju.....	192
6.2.3.1. Izbor eksperta domene.....	193
6.2.3.2. Rezultati odlučivanja.....	193
7. UTJECAJ REZULTATA DOBIVENIH ODLUČIVANJEM AHP I ANP METODOM.....	202
7.1. Hibridni model nastave na kolegiju Matematika.....	202
7.2. Strategija e-učenja Sveučilišta u Zagrebu i Fakulteta organizacije i informatike...	206
8. ZAKLJUČAK.....	211
LITERATURA.....	217
Popis priloga.....	229

Popis slika

Slika 1-1. Potreba za strateškim planiranjem uvođenja e-učenja u visoko školstvo u Hrvatskoj	6
Slika 2-1. Koraci uvođenja novih tehnologija u visoko obrazovanje	17
Slika 3-1. Potrebe pri uvođenju e-učenja na fakultetsku razinu (prilagođeno prema Markkula, 2002.)	27
Slika 3-2. Osam faza strateškog planiranja i donošenja odluke o uvođenju e-učenja (prilagođeno prema Markkula, 2002.)	37
Slika 4-1. Metoda "k srednjih vrijednosti"	56
Slika 4-2. Struktura ispitanika prema spolu	64
Slika 4-3. Struktura ispitanika prema starosnoj dobi	64
Slika 4-4. Struktura ispitanika prema školskoj spremi	65
Slika 4-5. Struktura ispitanika prema znanstveno-nastavnom zvanju	65
Slika 4-6. Struktura ispitanika prema znanstvenom području djelovanja	66
Slika 4-7. Struktura ispitanika prema instituciji/sektoru djelovanja	66
Slika 4-8. Struktura ispitanika prema radnom mjestu/funkciji	67
Slika 4-9. Prosječne ocjene važnosti ciljeva uvođenja e-učenja na sveučilišta/fakultete	69
Slika 4-10. Prosječne ocjene važnosti za prednosti uvođenja e-učenja na sveučilišta/fakultete	72
Slika 4-11. Prosječne ocjene važnosti za kriterije odlučivanja za uvođenje e-učenja na sveučilišta/fakultete	78
Slika 4-12. Prosječne ocjene važnosti za podkriterije odlučivanja za uvođenje e-učenja na sveučilišta/fakultete ($\bar{x} > 4$)	80
Slika 4-13. Prosječne ocjene važnosti za podkriterije odlučivanja za uvođenje e-učenja na sveučilišta/fakultete ($\bar{x} < 4$)	81
Slika 4-14. Matrica klastera	96
Slika 5-1. Hijerarhijski model – AHP struktura (Dyer, 1991., Saaty, 1991.)	101
Slika 5-2. Klasteriranje pri uspoređivanju nehomogenih elemenata	116
Slika 5-3. Tematska distribucija AHP aplikacija (prilagođeno prema Vaidya & Kumar, 2006.)	119
Slika 5-4. Područja primjene AHP-a (prilagođeno prema Vaidya & Kumar, 2006.)	119
Slika 5-5. Vremenska distribucija AHP publikacija (prilagođeno prema Vaidya & Kumar, 2006.)	120
Slika 5-6. Integracija AHP metode s drugim metodama prema broju publikacija (prilagođeno prema Ho, 2008.)	120

Slika 5-7. Četiri čimbenika koji utječu na uspješnost grupe u odlučivanju (Sikavica & Bebek, 1994.)	135
Slika 5-8. Skupine donositelja odluka s obzirom na znanja njihovih članova (Sikavica & Bebek, 1994.)	136
Slika 5-9. Rezultati grupnog odlučivanja AHP metodom za kolegij Matematika – Prioriteti alternativa	138
Slika 5-10. Rezultati grupnog odlučivanja AHP metodom za kolegij Matematika – Hijerarhijsko stablo s težinskim koeficijentima kriterija i podkriterija	139
Slika 5-11. Provedba i rezultati numeričkog uspoređivanja AHP metodom na razini kriterija	142
Slika 5-12. Analiza osjetljivosti – opcija <i>Dynamic</i> iz čvora cilja	144
Slika 5-13. Analiza osjetljivosti – opcija <i>Performance</i> iz čvora cilja	145
Slika 5-14. Analiza osjetljivosti – opcija <i>Gradient</i> za kriterij „Organizacijska i strateška spremnost okruženja“	147
Slika 5-15. Analiza osjetljivosti – opcija <i>Gradient</i> za kriterij „Raspoloživost temeljne ICT infrastrukture“	147
Slika 5-16. Analiza osjetljivosti – opcija <i>Gradient</i> za kriterij „Ljudski resursi“	148
Slika 5-17. Analiza osjetljivosti – opcija <i>Gradient</i> za kriterij „Formalno-pravna spremnost okruženja“	148
Slika 5-18. Analiza osjetljivosti – opcija <i>Gradient</i> za kriterij „Raspoloživost specifične infrastrukture“	149
Slika 5-19. Analiza osjetljivosti – opcija <i>Head to head</i> za alternative „Klasična nastava“ i „Nastava uz pomoć ICT“	151
Slika 5-20. Analiza osjetljivosti – opcija <i>Head to head</i> za alternative „Hibridna ili mješovita nastava“ i „Klasična nastava“	151
Slika 5-21. Analiza osjetljivosti – opcija <i>Head to head</i> za alternative „Online obrazovanje“ i „Klasična nastava“	152
Slika 5-22. Analiza osjetljivosti – opcija <i>Head to head</i> za alternative „Online obrazovanje“ i „Nastava uz pomoć ICT-a“	152
Slika 5-23. Analiza osjetljivosti – opcija <i>Head to head</i> za alternative „Online obrazovanje“ i „Hibridna ili mješovita nastava“	153
Slika 5-24. Analiza osjetljivosti – opcija <i>Head to head</i> za alternative „Hibridna ili mješovita nastava“ i „Nastava uz pomoć ICT-a“	153
Slika 5-25. Analiza osjetljivosti – opcija 2 D za kriterije „Temeljna ICT infrastruktura“ i „Organizacijska i strateška spremnost okruženja“	156
Slika 5-26. Analiza osjetljivosti – opcija 2 D za kriterije „Organizacijska i strateška spremnost okruženja“ i „Formalno-pravna spremnost okruženja“	157
Slika 5-27. Analiza osjetljivosti – opcija 2 D za kriterije „Ljudski resursi“ i „Organizacijska i strateška spremnost okruženja“	157

Slika 5-28. Analiza osjetljivosti – opcija 2 D za kriterije „Specifična infrastruktura“ i „Temeljna ICT infrastruktura“	158
Slika 5-29. Analiza osjetljivosti – opcija 2 D za kriterije „Ljudski resursi“ i „Temeljna ICT infrastruktura“	158
Slika 5-30. Analiza osjetljivosti – opcija 2 D za kriterije „Formalno-pravna spremnost okruženja“ i „Temeljna ICT infrastruktura“	159
Slika 5-31. Analiza osjetljivosti – opcija 2 D za kriterije „Specifična infrastruktura“ i „Organizacijska i strateška spremnost okruženja“	159
Slika 5-32. Analiza osjetljivosti – opcija 2 D za kriterije „Ljudski resursi“ i „Specifična infrastruktura“	160
Slika 5-33. Analiza osjetljivosti – opcija 2 D za kriterije „Ljudski resursi“ i „Formalno-pravna spremnost okruženja“	160
Slika 5-34. Analiza osjetljivosti – opcija 2 D za kriterije „Specifična infrastruktura“ i „Formalno-pravna spremnost okruženja“	161
Slika 5-35. Analiza osjetljivosti – opcija <i>Dynamic</i> iz čvora cilja, varijacija kriterija „Formalno-pravna spremnost okruženja“ za 5 %	162
Slika 5-36. Analiza osjetljivosti – opcija <i>Dynamic</i> iz čvora cilja, varijacija kriterija „Organizacijska i strateška spremnost okruženja“ za 50 %	163
Slika 6-1. Linearna hijerarhija	166
Slika 6-2. Mreža povratnih veza	166
Slika 6-3. Povratna veza u ANP-u – primjer «Odabir mosta»	168
Slika 6-4. Procjene dobivene uspoređivanjem elemenata u paru u skladu s povratnom vezom – primjer «Odabir mosta»	168
Slika 6-5. Prioriteti kriterija i alternativa - primjer «Odabir mosta»	168
Slika 6-6. Struktura BOCR ANP modela	174
Slika 6-7. Tipovi komponenata u ANP mreži	175
Slika 6-8. Supermatrica mreže	178
Slika 6-9. Blok (komponenta) supermatrice	178
Slika 6-10. Supermatrica hijerarhije	178
Slika 6-11. Supermatrica holarhije	179
Slika 6-12. Granična matrica hijerarhije	179
Slika 6-13. ANP model za donošenje odluke o uvođenju e-učenja u visoko školstvo	188
Slika 6-14. Alat <i>SuperDecisions</i> – odabir predložka za kreiranje ANP modela	192
Slika 6-15. Rezultati odlučivanja eksperta domene ANP metodom – Težinski koeficijenti elemenata (screenshot alata <i>SuperDecisions</i>)	195
Slika 6-16. Rezultati odlučivanja eksperta domene ANP metodom – Prioriteti alternativa	197

Slika 6-17. Rezultati odlučivanja eksperta domene ANP metodom – Matrica klastera	197
Slika 6-18. Rezultati odlučivanja eksperta domene ANP metodom – Granična supermatrica 01	198
Slika 6-19. Rezultati odlučivanja eksperta domene ANP metodom – Granična supermatrica 02	198
Slika 6-20. Rezultati odlučivanja eksperta domene ANP metodom – Granična supermatrica 03	199
Slika 7-1. Hibridni oblik učenja na kolegiju Matematika 1 u sustavu Moodle (<i>Screenshot 01</i>)	205
Slika 7-2. Hibridni oblik učenja na kolegiju Matematika 1 u sustavu Moodle (<i>Screenshot 02</i>)	205
Slika 7-3. Hibridni oblik učenja na kolegiju Matematika 1 u sustavu Moodle (<i>Screenshot 03</i>)	206

Popis tablica

Tablica 2-1. SWOT analiza e-učenja (prilagođeno prema: Hunjak & Begičević, 2006.)	14
Tablica 3-1. Popis aktivnosti i vremenski plan njihova izvršenja u EQIBELT projektu	31
Tablica 3-2. Četiri faze strateškog planiranja i donošenja odluke o uvođenju e-učenja (prilagođeno prema Dyer, 1991.)	36
Tablica 4-1. Mjere centralnih tendencija skupova podataka (Huzak, 2003.)	50
Tablica 4-2. Mjere raspršenja podataka (Huzak, 2003.)	51
Tablica 4-3. Identificirane prednosti uvođenja e-učenja	59
Tablica 4-4. Identificirani ciljevi uvođenja e-učenja	59
Tablica 4-5. Identificirani kriteriji i podkriteriji za donošenje odluke o uvođenju e-učenja	60
Tablica 4-6. Statistički pokazatelji za varijable koje se odnose na ciljeve uvođenja e-učenja na sveučilišta/fakultete	70
Tablica 4-7. Statistički pokazatelji za varijable koje se odnose na prednosti uvođenja e-učenja na sveučilišta/fakultete	73
Tablica 4-8. Statistički pokazatelji za varijable koje se odnose na kriterij Organizacijska spremnost okruženja	74
Tablica 4-9. Statistički pokazatelji za varijable koje se odnose na kriterij Formalno-pravna spremnost okruženja	75
Tablica 4-10. Statistički pokazatelji za varijable koje se odnose na kriterij Raspoloživost temeljne ICT infrastrukture	75
Tablica 4-11. Statistički pokazatelji za varijable koje se odnose na kriterij Raspoloživost specifične infrastrukture i alata za e-učenje	76
Tablica 4-12. Statistički pokazatelji za varijable koje se odnose na kriterij Raspoloživost ljudskih resursa	77
Tablica 4-13. Statistički pokazatelji za varijable koje se odnose na kriterij Razvoj ljudskih resursa	77
Tablica 4-14. Postoci varijance rezultata dobiveni postupkom faktorske analize za teoretski model kriterija odlučivanja za uvođenje e-učenja	84
Tablica 4-15. Rotirana matrica komponenata s prikazom projekcije varijance na pojedini faktor za teoretski model kriterija odlučivanja za uvođenje e-učenja	85
Tablica 4-16. Postoci varijance rezultata dobiveni postupkom faktorske analize za reducirani model kriterija odlučivanja za uvođenje e-učenja	87
Tablica 4-17. Rotirana matrica komponenata s prikazom projekcije varijance na pojedini faktor za reducirani model kriterija odlučivanja za uvođenje e-učenja	88
Tablica 4-18. Usporedba postavljenog teoretskog modela kriterija odlučivanja za uvođenje e-učenja iz upitnika i faktora koji su ekstrahirani faktorskom analizom	89

Tablica 4-19. Broj iteracija potrebnih u provedenom klasteriranju metodom k srednjih vrijednosti	91
Tablica 4-20. Pripadnost slučajeva pojedinom klasteru	92
Tablica 4-21. Slučajevi najmanje udaljenosti od centra klastera	94
Tablica 4-22. Finalna klasterizacija	95
Tablica 4-23. Broj slučajeva u svakom od klastera	95
Tablica 4-24. Udaljenost između centara finalnih klastera	97
Tablica 5-1. Saaty-eva skala relativne važnosti (Saaty, 1980., 1991.)	102
Tablica 5-2. Formiranje omjera uspoređivanjem elemenata u parovima	103
Tablica 5-3. Omjeri dobiveni uspoređivanjem elemenata u parovima	103
Tablica 5-4. Normalizirana matrica i prioriteti alternativa	104
Tablica 5-5. Vrijednosti RI slučajnih indeksa (Saaty, 1980.)	112
Tablica 5-6. Pregled primjena AHP-a	118
Tablica 5-7. Opis alternativa (karakteristike oblika e-učenja) (prilagođeno prema Zemsky, 2004.)	122
Tablica 5-8. Ekspertiza sudionika procesa grupnog odlučivanja o obliku uvođenja e-učenja na kolegij Matematika	136
Tablica 5-9. Rezultati grupnog odlučivanja AHP metodom za kolegij Matematika - Pregled težinskih koeficijenata kriterija i podkriterija	140
Tablica 6-1. Ponderirana matrica jednaka neponderiranoj matrici - primjer «Odabir mosta»	170
Tablica 6-2. Granična matrica - primjer «Odabir mosta»	170
Tablica 6-3. Broj publikacija (≥ 3) ANP metode prema autorima u razdoblju od 1996 – 2006 godine	183
Tablica 6-4. Broj publikacija (≥ 3) AHP metode prema autorima u razdoblju od 1980 – 1990 godine	183
Tablica 6-5. Broj publikacija (≥ 3) ANP metode prema zemlji objave u razdoblju od 1996 – 2006 godine	184
Tablica 6-6. Broj publikacija (≥ 3) AHP metode prema zemlji objave u razdoblju od 1980 – 1990 godine	184
Tablica 6-7. Usporedba broja publikacija AHP i ANP metode u prvih 10 godina postojanja metoda	185
Tablica 6-8. Matrica veza elemenata u ANP modelu	190
Tablica 6-9. Ekspertiza eksperta domene	193
Tablica 6-10. Rezultati odlučivanja eksperta domene ANP metodom – Pregled težinskih koeficijenata elemenata	196
Tablica 7-1. Objašnjenje razine «hibridne nastave» za kolegij Matematika 1	203

1. UVOD

Pitanja kvalitete obrazovnog procesa i ishoda obrazovanja, valorizacije povećanih ulaganja resursa i vlastitog vremena u obrazovni proces, te pitanja vezana uz što uspješniju provedbu Bolonjskog procesa, traže odgovore koji bi vodili rješenju nekih problema u visokom obrazovanju.

Problemi u visokom obrazovanju su sve veći, troškovi obrazovanja rastu, postavlja se pitanje efikasnosti školovanja te prilagodbe nastavnog procesa studentu vičnom ICT-u, povećava se broj studenata, zapošljava se neiskusni nastavni kadar, interakcije između studenata i profesora je sve manje, profesori imaju povećane nastavne obveze, a vremena za znanstveni rad sve više nedostaje.

Uprave visokih učilišta, profesori i nastavnici trebaju prepoznati mogućnosti rješavanja tih problema, te ih primijeniti kako bi se postigli ciljevi definirani od strane visokoškolskih institucija te riješili problemi koji su u visokom obrazovanju sve kompleksniji i brojniji. Primjena informacijske tehnologije, pa tako i tehnologija e-učenja jedna je od mogućnosti koja može doprinijeti poboljšanju kvalitete obrazovanja, pomičući granice u komunikaciji nastavnika i studenata i granice u dostupnosti obrazovanja, ali i implementaciji koncepata cjeloživotnog učenja. Uprave visokih učilišta trebaju jasno definirati ciljeve obrazovnog sustava, u okviru kojih treba i strateški planirati integraciju informacijsko-komunikacijske tehnologije te e-učenja u cjelokupni obrazovni proces.

Istraživanje provedeno u okviru ove doktorske disertacije, svojim će rezultatima dati doprinos strateškom planiranju i donošenju odluka u procesu uvođenja e-učenja u visoko školstvo u Hrvatskoj.

Uvodna poglavlja 1.1. i 1.2. detaljnije opisuju problem istraživanja te ciljeve i podciljeve istraživanja i zadane hipoteze.

1.1. Opis problema istraživanja

Kvaliteta obrazovanja, učinkovitost obrazovnog procesa, te relevantnost i održivost znanja kao rezultata procesa obrazovanja, problemi su s kojima je trenutno suočeno europsko visoko obrazovanje, pa tako i hrvatsko. Istovremeno se sustavi visokog obrazovanja bore i s problemima ograničenih financijskih i fizičkih resursa, te s porastom broja studenata i heterogenosti obrazovnih grupa. Potrebe, kao što su raspoloživost nastavnika, kvalitetna i česta komunikacija te individualan pristup u okruženju timskog rada, nametnute su u uvjetima u kojima nije realno očekivati bitno povećanje broja nastavnika.

Prepoznata je globalna važnost znanja i obrazovanja i konkurencija na tržištu znanja postaje sve veća. Visokoškolske institucije trebaju riješiti probleme i izazove koji im se nameću, a jedan od načina njihova rješavanja je i primjena informacijsko-komunikacijske tehnologije u obrazovanju, naročito tehnologija e-učenja, kako bi se unaprijedila kvaliteta podučavanja i učenja te povećala učinkovitost uporabe postojećih ljudskih i materijalnih resursa.

E-učenje donosi mnoge prednosti koje treba iskoristiti na način da se pronade adekvatna primjena metoda i tehnologija e-učenja, te ih se učinkovito i na način prilagođen stvarnim uvjetima i okolini, integrira u procese obrazovanja na Sveučilištu. Uvođenje e-učenja jedan je od ciljeva koje treba realizirati Sveučilište te uspješnom implementacijom iskoristiti prednosti koje e-učenje donosi dugoročno, ali i kratkoročno, od dostupnosti znanja i sadržaja, posebno u slučajevima dislociranosti velikog broja studenata do mogućnosti cjeloživotnog obrazovanja i novih oblika komuniciranja s nastavnicima i studentima.

Prema Batesu (Bates, 2004.), neki od osnovnih motiva za primjenu e-učenja u učenju i podučavanju su: poboljšanje kvalitete učenja, smanjenje troškova obrazovanja, povećanje isplativosti ulaganja u obrazovanje, proširenje dostupnosti obrazovanja i osposobljavanja, odgovor na “imperative tehnologije”, kvalitetniji rad s većim grupama studenata, savladavanje vještina rukovanja informacijskom tehnologijom i dr.

Pomak visokoškolskih institucija prema e-učenju treba biti dio strateškog planiranja i odlučivanja u visokom školstvu. Na razini sveučilišta potrebno je kreirati i formalno prihvatiti strategiju primjene e-učenja, te uspostaviti formalno-pravne okvire za vrednovanje i sveobuhvatnu primjenu e-učenja. Važno je osigurati izvore financiranja za uvođenje e-učenja te osmisliti i staviti u funkciju sustav potpore sveučilišnim nastavnicima, kako bi primjena informacijskih i komunikacijskih tehnologija, a posebno tehnologija e-učenja, bila što jednostavnija i učinkovitija.

Na razini fakulteta, implementacija e-učenja ne može uspjeti bez podrške i motivacije glavnih interesnih grupa, nastavnika i studenata. Fakulteti trebaju definirati strateške odrednice u razvojnim planovima fakulteta, uspostaviti infrastrukturu za implementaciju e-učenja te motivirati i omogućiti adekvatno usavršavanje pomoćnog osoblja i nastavnika za korištenje sustava podrške e-učenju. Slika 1-1. prikazuje potrebu za strateškim planiranjem uvođenja e-učenja u visoko školstvo u Hrvatskoj.

Sadašnje stanje u Hrvatskoj pokazuje da je svijest o važnosti kulture i politike kvalitete u visokoj naobrazbi visoka, te da je e-učenje upravo jedan od načina postizanja željene razine kvalitete u visokom obrazovanju koja će zadovoljiti sve više zahtjeve tržišta i društva. Metode i tehnologije e-učenja potrebno je integrirati u obrazovne procese te tako uspješno promovirati primjene metoda i tehnologija e-učenja kao alata za poboljšanje kvalitete sveučilišnog obrazovanja (Slika 1-1.).

Navedeni ciljevi nastoje se realizirati u okviru Tempus projekt EQIBELT: *Education Quality Improvement by E-Learning Technology* (EQIBELT, 2006.) koji je započeo u 9. mjesecu 2005. na zajedničku inicijativu Sveučilišta u Zagrebu, Rijeci i Dubrovniku, zajedno s konzorcijem sastavljenim od 13 institucija uz koordiniranje SRCA (EQIBELT, 2006.). Trajanje projekta je 3 godine i u tom vremenu će se nastojati poboljšati kvaliteta sveučilišnog obrazovanja primjenom metoda i tehnologija e-učenja, izraditi i prihvatiti formalnopravni i tehnološki okvir te osmisliti i uspostaviti trajno održiv sustav centara potpore za e-učenje u visokom školstvu. Očekivani rezultati projekta su (EQIBELT, 2006.): (1) prihvaćanje vizije primjene e-učenja na svakom od hrvatskih sveučilišta - članova konzorcija (2) strateški i provedbeni dokumenti vezani uz implementaciju e-učenja na svakom od sveučilišta (3) minimalni tehnički standardi za projekte e-učenja na sveučilištima (4) centri potpore projektima e-učenja na svakom od hrvatskih sveučilišta-članova konzorcija i (5) pilot projekti u području primjene e-učenja.

Istraživanje koje je provedeno u okviru ove doktorske disertacije, bilo je strukturirano na način da izvrši prikupljanje podataka potrebnih u izradi strateških dokumenata (strategija visokoškolskih institucija): ciljeva i prednosti e-učenja te kriterija odlučivanja važnih za strateško planiranje i donošenje odluka o uvođenju e-učenja. Na temelju prikupljenih podataka razvijeni su modeli za višekriterijsko odlučivanje koji imaju svoju primjenu u donošenju odluka (na razini sveučilišta, fakulteta, katedre i kolegija) u procesu strateškog planiranja uvođenja e-učenja na visokoškolske institucije u Hrvatskoj.

U procesu strateškog planiranja i donošenja odluke o uvođenju e-učenja mogu se izdvojiti četiri osnovne faze: (1) faza istraživanja problema, (2) faza razvijanja i izgradnje modela, (3) faza donošenja odluka i (4) faza provođenja odluke. Provedeno istraživanje dalo je svoj doprinos u prve tri faze. U fazi istraživanja problema precizno je definiran centralni problem te je izvršena analiza situacije koja je uključila pregled i prezentaciju ključnih faktora i trendova vezanih uz definirani problem. U fazi razvijanja i izgradnje modela, na temelju mnogih znanstvenih i stručnih izvora, te primjera strategija e-učenja vodećih europskih fakulteta (detaljnije u poglavlju 3.2.1.), identificirani su ciljevi i prednosti e-učenja te kriteriji za odlučivanje o uvođenju e-učenja u visoko školstvo. Ciljevi i prednosti e-učenja te kriteriji za odlučivanje služili su kao podloga za kreiranje ankete čiji cilj je bio prikupljanje podataka od ispitanika, stručnjaka (eksperata) za e-učenje u visokom školstvu. Rezultati anketiranja obrađeni su faktorskom analizom koja je reducirala skup definiranih kriterija odnosno reducirala veći broj varijabli na manji broj faktora. Na temelju rezultata faktorske analize, razvijeni su modeli za višekriterijsko odlučivanje: Analitički hijerarhijski proces (AHP) i Analitički mrežni proces (ANP) koji služe kao potpora u donošenju odluke o uvođenju e-učenja u visoko školstvo na višim razinama (sveučilišta i fakulteta) te nižim razinama (katedre i kolegija). U fazi donošenja odluke izvršeno je testiranje razvijanih modela. Provedeno je grupno odlučivanje AHP metodom o uvođenju e-učenja na razini kolegija te odlučivanje o problemu uvođenja e-učenja na razini institucije koje je provedeno od strane eksperta domene uz potporu ANP modela.

U postupku razvoja AHP i ANP modela primijenjena je po prvi puta kombinirana metoda istraživanja koja je obuhvatila sljedeće metode: anketu kojom su prikupljeni podaci od eksperata, deskriptivnu statistiku za obradu prikupljenih podataka, klasteriranje za analizu podataka i


faktorsku analizu za reduciranje kriterija. Primjenom kombinirane metode je integrirano i racionalizirano znanje eksperata. Važno je naglasiti i kombinaciju ekspertiza ispitanika u istraživanju, odnosno da su u istraživanju sudjelovali isključivo ispitanici koji su eksperti i u području e-učenja i visokog školstva.

AHP i ANP modeli za donošenje odluke o uvođenju e-učenja u visoko školstvo, također su prvi puta primijenjeni kao potpora u rješavanju problema strateškog planiranja uvođenja e-učenja. AHP metoda je danas jedna od najpopularnijih metoda za višekriterijsko odlučivanje s velikim spektrom primjena, međutim AHP model, koji je razvijen kombiniranom metodom i koji rješava probleme u domeni strateškog planiranja e-učenja, nije do sada razvijen niti primijenjen u rješavanju te vrste problema (opisano u poglavlju 5.2.).

Izgradnjom hijerarhijskog modela za određeni složeni problem, izvršena je sistematizacija znanja o problemu i jasno definiranje kriterija, podkriterija, ciljeva i alternativa odluke. Razvijeni AHP model obuhvaća cjelinu problema (interaktivno kreiranje hijerarhije problema kao pripreme scenarija odlučivanja o uvođenju e-učenja na visokoškolske institucije) te podupire donošenje odluke o određenom problemu odlučivanja vodeći računa o kvalitativnim i kvantitativnim aspektima odluke i konzistentnosti donositelja odluke. Pomoću takvog modela mogu se donositi odluke o strateškom uvođenju e-učenja unutar pojedinih institucija visokog školstva (na razini katedre i kolegija), fokusirati se na strateške vrijednosti dobivenih rješenja i koristiti ih za povećanje učinkovitosti implementacije i razvoj sustava u planiranom smjeru.

ANP metoda je novija i naprednija metoda od AHP-a te uključuje dodatna poboljšanja u odnosu na AHP, prije svega daje veću stabilnost rješenja pa je primijenjena za donošenje odluka na višim, strateškim razinama. ANP model uključuje i funkcionalnu interakciju kriterija i alternativa te ostalih elemenata problema te određuje njihove zavisnosti i ostale poveznice. U tom okviru generiran je model i provedeno je odlučivanje (opisano u poglavlju 6.2.). ANP metoda nikada prije nije primjenjivana za rješavanje problema u domeni visokog školstva, a njenih primjena općenito ima malo i gotovo sve su napravljene u 2005. i 2006. godini.

Osnovne prednosti primjene AHP i ANP metoda za višekriterijsko odlučivanje su: sistematizacija i povećanje znanja o problemu, iterativno ili direktno provođenje vrednovanja od strane donositelja odluke imajući u glavi cjelinu problema, donošenje odluke te dolazak do rješenja problema velikom brzinom i s malim troškovima, provjera konzistentnosti procjena donositelja odluke, simuliranje rezultata preko analize osjetljivosti te korištenje dobivenih rezultata kao inputa za projekt ili za kompleksniju odluku.



Slika 1-1. Potreba za strateškim planiranjem uvođenja e-učenja u visoko školstvo u Hrvatskoj

1.2. Hipoteze i ciljevi istraživanja

Istraživanje koje je provedeno u okviru doktorske disertacije je kombinirano (mješovito) kvalitativno i kvantitativno istraživanje (Creswell, 2003.) provedeno s ciljem boljeg razumijevanja i lakšeg rješavanja problema istraživanja. Kvalitativno istraživanje omogućilo je uvid u trenutačno stanje vezano uz problem istraživanja i obuhvatilo je kvalitativnu analizu primjera strategija e-učenja vodećih europskih sveučilišta i fakulteta. Kvalitativna analiza koristila se i kod analize strategija e-učenja Sveučilišta u Zagrebu i Fakulteta organizacije i informatike te se pomoću nje utvrdio doprinos rezultata provedenog istraživanja u postupku definiranja strategija. Kvantitativno istraživanje korišteno je za dobivanje statističkih podataka koji su omogućili identifikaciju i određivanje važnosti prednosti i ciljeva uvođenja e-učenja, te identifikaciju i ocjenu važnosti kriterija odlučivanja. Na temelju definiranih kriterija razvijeni su modeli za višekriterijsko odlučivanje: AHP i ANP model, koji su testirani u procesu grupnog i individualnog odlučivanja. Detaljni opisi provedenog kvalitativnog i kvantitativnog istraživanja nalaze se u poglavljima 4, 5, 6 i 7.

U skladu s problemom istraživanja definirani su ciljevi i podciljevi istraživanja.

Ciljevi istraživanja su:

- sistematizirati postojeće strategije e-učenja vodećih europskih sveučilišta i fakulteta,
- identificirati prednosti i ciljeve e-učenja te kriterije za odlučivanje kod uvođenja e-učenja u visoko školstvo u Hrvatskoj na temelju primjera strategija e-učenja vodećih europskih sveučilišta i fakulteta,
- ocijeniti važnost prednosti i ciljeva e-učenja te važnost kriterija odlučivanja kod uvođenja e-učenja,
- dati preporuku u odlučivanju o uvođenju e-učenja na razini katedre i/ili kolegija pomoću AHP modela,
- dati preporuku u odlučivanju o uvođenju e-učenja na razini sveučilišta i/ili fakulteta pomoću ANP modela, te
- dati potporu strateškom planiranju i izradi strateških dokumenata uvođenja e-učenja u okviru Tempus projekta EQIBELT (Sveučilište u Zagrebu) i Fakulteta organizacije i informatike.

Podciljevi istraživanja su:

- anketirati ispitanike (odabir ispitanika u skladu s ekspertizom: e-učenje u visokom školstvu u Hrvatskoj) sa svrhom ocjenjivanja važnosti prednosti i ciljeva e-učenja te važnosti kriterija odlučivanja kod uvođenja e-učenja,
- primijeniti metodu k srednjih vrijednosti s ciljem grupiranja ispitanika u klastere,
- provesti faktorsku analizu sa svrhom reduciranja skupa kriterija,
- razviti AHP model (Analitički hijerarhijski proces) na temelju reduciranog skupa kriterija,
- testirati AHP model za donošenje odluke o uvođenju e-učenja na razini katedre i/ili kolegija,
- razviti ANP model (Analitički mrežni proces) na temelju reduciranog skupa kriterija i složenih interakcija između kriterija odlučivanja, te
- testirati ANP model za donošenje odluke o uvođenju e-učenja na razini sveučilišta i/ili fakulteta.

Kako bi se eksplicitno odredio smjer istraživanja, postavljene su i tri hipoteze:

- **H1:** U procesu strateškog planiranja uvođenja e-učenja na visokoškolske institucije, moguće je identificirati i ocijeniti važnost ciljeva i prednosti e-učenja te važnost kriterija za odlučivanje kod uvođenja e-učenja.
- **H2:** Na temelju definiranih kriterija, moguće je razviti AHP model te grupnim odlučivanjem metodom analitičkog hijerarhijskog procesa donijeti odluku o obliku uvođenja e-učenja na razini katedre i kolegija.
- **H3:** Kod donošenja odluka u procesu strateškog planiranja uvođenja e-učenja na razini sveučilišta i fakulteta, pojavljuju se složene interakcije između kriterija za odlučivanje i one se mogu modelirati pomoću analitičkog mrežnog procesa.

Detaljno objašnjenje hipoteza te postupak dokazivanja navedenih hipoteza nalazi se u poglavljima 4, 5 i 6.

2. E-UČENJE U VISOKOM ŠKOLSTVU

Informatizacija je postala dio svakidašnjeg života i komuniciranja, unaprijedila je gotovo sva područja, te stvorila jedinstveno svjetsko globalno tržište informacija i tehnologije. Kvalitetna i promišljena primjena informacijskih i komunikacijskih tehnologija (ICT) omogućila je veliki napredak u procesu obrazovanju, poboljšala je kvalitetu učenja i podučavanja i povećala dostupnost znanja. Uvođenje e-učenja kao jednog od načina primjene suvremene informacijske tehnologije, stvorilo je poticajnu i pozitivnu klimu za mnoge pomake u obrazovanju, pa e-učenje možemo opravdano nazvati katalizatorom promjena u visokom obrazovanju.

Važnost uvođenja e-učenja u visokoškolske institucije te prednosti koje ono donosi, ali i problemi i izazovi uvođenja e-učenja u visoko školstvo, opisani su u poglavljima 2.1. i 2.2. Pregled važnijih istraživanja o e-učenju u visokom školstvu dan je u poglavlju 2.3.

2.1. Definicija i važnost e-učenja

E-učenje je prilično teško jednoznačno definirati. Neki autori smatraju da je e-učenje isključivo oblik učenja koje je u potpunosti online tzv. „čisto“ e-učenje koje predstavlja oblik nastave pri kojem studenti uče u potpunosti samostalno i online (Oblinger & Hawkins, 2005., Curranu, 2004.), dok drugi smatraju da je e-učenje tzv. mješovito ili hibridno obrazovanje koje predstavlja kombinaciju klasične nastave u učionici i nastave uz pomoć tehnologija (ICT) (Bates, 2005., CEC, 2001.). E-učenje kao oblik podučavanja postoji na više razina: kao potpuno samostalan oblik, ali i kao sastavni dio ili dopuna klasičnog obrazovanja. U skladu s time razlikuju se i definicije e-učenja prema raznim autorima.

Oblinger and Hawkins (Oblinger & Hawkins, 2005.) tvrde da se učenje može smatrati e-učenjem ukoliko je cijeli kolegij online i ako se sva interakcija između nastavnika i studenata odvija preko mreže.

Prema definiciji HEFCE-a (Higher Education Funding Council for England, 2005.), e-učenje je svako učenje koje koristi informacijsko-komunikacijsku tehnologiju.

CEC (Commission of the European Communities, 2001.) u svojem dokumentu „The eLearning Action Plan“ definira e-učenje kao primjenu novih multimedijских tehnologija i Interneta s ciljem poboljšanja kvalitete učenja, na način da se podupre pristup sadržajima i uslugama i omogućе utjecaji, promjene i kolaborativnost u uvjetima dislociranosti.

Prema Curranu (Curranu, 2004.), e-učenje se može na najjednostavniji način definirati kao proces učenja u kojem studenti preko Interneta ili preko drugih računalnih mreža, komuniciraju sa svojim instruktorima i međusobno te pristupaju nastavnim materijalima potrebnim za učenje.

Definicija e-učenja koja je možda najčešće citirana je definicija T.Batesa (Bates, 2005.) koji kaže da e-učenje uključuje sve računalno te Internetski podržane aktivnosti koje podupiru učenje i podučavanje unutar i izvan učionice.

Opća definicija e-učenja prihvaćena u okviru Strategije e-učenja 2007. – 2010. Sveučilišta u Zagrebu (Strategija e-učenja Sveučilišta u Zagrebu, 2007.) definira e-učenje kao proces obrazovanja (proces učenja i podučavanja) uz uporabu informacijske i komunikacijske tehnologije, koja doprinosi unapređenju kvalitete toga procesa i kvalitete ishoda obrazovanja.

U okviru Strategije uvođenja e-učenja na Sveučilištu u Rijeci 2006-2010 (Strategija uvođenja e-učenja na Sveučilištu u Rijeci, 2006.), e-učenje se definira kao pojam koji opisuje obrazovni proces unaprijeđen uporabom novih informacijsko-komunikacijskih tehnologija (ICT). E-učenje je bilo koji oblik učenja, poučavanja ili obrazovanja koji je potpomognut prvenstveno onim tehnologijama koje se temelje na Internetu (webu).

U izvještaju COIMBRA grupe (Coimbra group, 2002.), e-učenje se smatra pokretačem promjena u obrazovanju te se spominje kao jedna od najvažnijih mogućnosti za modernizaciju sveučilišta koja odgovora na izazove društvenih i političkih pritisaka širenja visokog obrazovanja i primjene cjeloživotnog učenja.

Važnost e-učenja velika je u okvirima unaprjeđenja kvalitete obrazovanja na sveučilištima te unapređenju rezultata obrazovnog procesa. E-učenje daje svoj veliki doprinos u svakodnevnoj

organizaciji obrazovnog procesa, u vremenskoj i prostornoj fleksibilnosti u podučavanju i učenju te neograničenoj dostupnosti znanja i obrazovnih sadržaja. E-učenje omogućuje kvalitetniju i jednostavniju komunikaciju nastavnika i studenata te ih potiče na aktivniju suradnju. Obrazovanje postaje dostupno studentima na udaljenim lokacijama, studentima s invaliditetom i stranim studentima te time e-učenje omogućava veću dostupnost obrazovanja i povećava postotak visokoobrazovanog kadra. E-učenje unapređuje i ishode obrazovnog procesa, stvaranjem kvalitetnih stručnjaka sa sposobnostima cjeloživotnog učenja, te vještinama svrsishodne primjene ICT-a.

Važnost cjeloživotnog učenja, a time i e-učenja naglašena je i u Lisabonskoj strategiji za povećanje konkurentnosti Europske unije (Lisabonska strategija, 2000.) u kojoj je Europska unija zacrtala ciljeve koji bi se trebali ostvariti do 2010. godine. Na sjednici Europskog vijeća u Lisabonu, održanoj 23. i 24. ožujka 2000. godine, utvrđena je strategija gospodarskog razvitka Europske unije do 2010. godine s ciljem povećavanja zaposlenosti i životnog standarda u ekonomiji zasnovanoj na znanju. Ulaganje u ljudski kapital, doškoloavanje i stalna izobrazba (cjeloživotno obrazovanje), razvoj računalne pismenosti te ostalih vještina za društvo znanja, jasno čine okosnicu strategije. Lisabonska strategija ne obvezuje zakonski već politički zemlje članice EU-a pa će Hrvatska kao buduća članica EU-a morati raditi na realizaciji lisabonskih ciljeva koji bi trebali postati pokretač gospodarske razvojne politike zemlje.

Dokumentom Ministarstva znanosti, obrazovanja i športa "Plan razvoja odgoja i obrazovanja 2005.-2010." (Plan razvoja sustava odgoja i obrazovanja, 2005.), pokrenut je proces promjena u obrazovnom sustavu koji svojim pozitivnim učincima može doprinijeti potrebnom rastu i razvoju. U dokumentu je stavljen naglasak na potrebe razvoja navika cjeloživotnog učenja radi osobnog razvoja, stjecanja novih znanja, te efikasnije prilagodbe tržištu rada i novim životnim okolnostima.

U okviru "Razvojne strategije Sveučilišta u Zagrebu ISKORAK 2001" (Razvojna strategija Sveučilišta u Zagrebu - ISKORAK 2001, 2001.) kojom se određuje temeljna zadaća Sveučilišta, potrebno je izdvojiti neke od glavnih ciljeva navedenih u strategiji: razvoj cjeloživotnog obrazovanja, prilagodba nastavnih programa europskim iskustvima i trendovima, zaživljavanje

visokih standarda i kriterija u sveučilišnom životu koji nas klasificiraju kao konkurentne partnere u Europi, osuvremenjivanje infrastrukture i razvoj sustava za osiguravanje kvalitete.

Važnost e-učenja mora se sagledati i sa aspekta podizanja kvalitete nastavnog procesa. E-učenje, kao i ostali oblici učenja uz potporu informacijsko-komunikacijske tehnologije, mogu povećati kvalitetu nastave i nastavnih sadržaja, osposobljavajući studente za rješavanje problema i samostalno odlučivanje. Kvaliteta nastave i nastavnih sadržaja podrazumijeva zadovoljstvo studenata kvalitetom svih segmenata nastave: s načinom prijenosa znanja, kredibilitetom nastavnika, dostupnošću i usvajanjem sadržaja i s mogućnosti traženja, analiziranja i interpretiranja informacija.

ENQA (European Network of Quality Assurance) je 2005. godine, temeljem zadatka Europske ministarske konferencije u Berlinu, objavila preporuke pod nazivom "Standards and Guidelines for QA in the European Higher Education Area" (Standards and Guidelines for Quality Assurance in the European Higher Education Area, 2005.). Standardi i smjernice su podijeljene u tri dijela, prvi dio se bavi problematikom osiguranja kvalitete u ustanovama visokog obrazovanja, drugi vanjskim evaluacijama, te treći agencijama za akreditaciju.

Prvi dio je nazvan „Europski standardi i smjernice za unutarnje osiguranje kvalitete u ustanovama visokog obrazovanja“ i sastoji se od sljedećih točaka:

- 1.1. strategija razvoja i postupci za osiguranje kvalitete – kultura kvalitete
- 1.2. nadziranje programa i kvalifikacija
- 1.3 ocjenjivanje studenata
- 1.4. osiguranje kvalitete nastavničkog kadra
- 1.5. izvori za učenje i pomoć studentima
- 1.6. sustav informiranja
- 1.7. javno informiranje.

E-učenje pomaže postizanju standarda 1.2, 1.3, 1.4, a osobito standarda 1.5. (Begičević & Divjak, 2006.).

Uvođenje e-učenja može ublažiti i posljedice pojava koje su često rezultati nekontrolirane ekspanzije visokog obrazovanja:

- povećane nastavne obveze,
- povećanje broja studenata,
- nedostatak vremena za znanstveni rad,
- zapošljavanje neiskusnog nastavnog kadra,
- pomanjkanje interakcije studenata i profesora.

E-učenje značajno obogaćuje komunikaciju u odgojno-obrazovnom procesu. Interaktivnost i komunikacija je drugačija kod e-učenja u odnosu na nastavu u predavaonici. Interakcija između studenata i nastavnika u predavaonici je direktna – lice u lice što naravno ima veliku prednost, međutim prepoznaje se trend porasta broja studenata, što rezultira tzv. masovnim studiranjem. E-učenje omogućuje individualni pristup nastavnika prema studentu te omogućuje neposrednu povratnu informaciju (*feedback*).

Primjena e-učenja može poboljšati i isplativost ulaganja u visokoškolsko obrazovanje na nekoliko načina: omogućiti ustanovi da dopre do većeg broja različitih studenata, smanjiti i/ili ukinuti pojedine aktivnosti koje izvode nastavnici, a koje bolje obavlja tehnologija (na taj način se nastavnicima oslobađa vrijeme za produktivnije aktivnosti) i povećati kvalitetu učenja, bilo da se osposobi studente da postižu bolje rezultate i nauče nove vještine ili da ih se osposobi da postojeće ciljeve postižu brže i jednostavnije.

Aktivnost, motiviranost i samodisciplina pojedinaca presudni su motivacijski čimbenici za uspješno odvijanje nastave. E-učenje jamči uspjeh samo kod jako motiviranih studenata jer studenti koji uče isključivo putem Interneta češće su podložni odustajanju od studija. Dostupnost i prilagodljivost obrazovanja te trend cjeloživotnog učenja pruža mogućnost da učenje postane važan dio cjelokupnog životnog vijeka čovjeka. E-učenje predstavlja idealno rješenje za korisnike obrazovnog sustava jer dopušta samostalnu organizaciju vremena i fizičku dislociranost.

Analiza prednosti i slabosti, prilika i prijetnja pri uvođenju e-učenja provedena je u okviru SWOT analize (Tablica 2-1.). SWOT analiza je sredstvo sustavske analize odnosa internih prednosti (*S-Strengths*) i slabosti (*W-Weaknesses*) i eksternih povoljnih prilika (*O- Opportunities*) i prijetnji (*T-Threats*) (Buble, 2000.).

Tablica 2-1. SWOT analiza e-učenja (prilagođeno prema: Hunjak & Begičević, 2006.)

Snage	Slabosti
<ul style="list-style-type: none"> ▪ Kreativno učenje (e-učenje je zabavnije i zanimljivije) (Parker, 2003.) ▪ Bolja vizualizacija i simulacija, inovacije i multimedijske mogućnosti (Bates, 2004.), (Morrison, 2003.) ▪ Kolaborativno učenje (Horton, 2000.); mogućnost dinamičke interakcije (Illinois Online Network, 2003.) (studenti imaju bolji pristup i interakciju s nastavnikom, mogućnost trenutnog <i>feedbacka</i> i diskusije s ostalim studentima) ▪ Prilagođavanje stilu učenja studenta (studenti uče nezavisno vlastitim tempom, nemaju potrebu mijenjati svoj stil učenja) (Horton, 2000.) ▪ Mogućnost integracije posla i učenja (Horton, 2000.); (Morrison, 2003.) ▪ Manji troškovi (troškovi putovanja svedeni na minimum, reducirani administrativni troškovi i dr.) (Bates, 2004.); (Horton, 2000.); (Rosenberg, 2001.) ▪ Ušteda vremena za studente i nastavnike (Bates, 2004.); (Horton, 2000.); ▪ Iskorištenje komunikacijskih aspekata uporabe informacijske tehnologije (Bates, 2004.) ▪ Dostupnost svih potrebnih nastavnih sadržaja putem Interneta (Illinois Online Network, 2003.), veća dostupnost znanja i informacija (Parker, 2003.) 	<ul style="list-style-type: none"> ▪ Studenti trebaju biti izuzetno motivirani, aktivni, s visokim samopouzdanjem i dobrom sposobnosti samoorganizacije (Illinois Online Network, 2003.) ▪ Strah od gubitka odgojnih i obrazovnih vrijednosti (studenti propuštaju timski rad, diskusije te izražavanje profesorovih stajališta i mišljenja „lice u lice“) (Hirschheim, 2005.) ▪ Strah od gubitka osobnog kontakta smanjenjem komunikacije licem u lice (Horton, 2000.), Internet ima potencijal da izolira studente (Hirschheim, 2005.) ▪ Mogućnost nerazumijevanja (Maurer, 2003.) i pogrešne interpretacije (Horton, 2000.) ▪ Financijska ulaganja i troškovi prilikom uspostave sustava (Hirschheim, 2005.) ▪ Tehnološka pripremljenost i tehnički preduvjeti studenata i nastavnika (Maurer, 2003.); (Illinois Online Network, 2003.) ▪ Potrebna reorganizacija (Bates, 2004.); (Morrison, 2003.) ▪ Mogućnost da dođe do nedovoljnog sudjelovanja studenata u interaktivnim online aktivnostima (strah od neugodnosti u javnosti) (Young, 2004.) ▪ Problem autorizacije nastavnih sadržaja na webu (Bates, 2004.) ▪ Problem identifikacije studenata (kod provjere znanja) (Bates, 2004.)

Prilike	Prijetnje
<ul style="list-style-type: none"> ▪ Učenje bilo gdje i bilo kada i tzv. „<i>just in time – any time</i>“ pristup (Rosenberg, 2001.) ▪ Cjeloživotno učenje (Howel, 2003.) ▪ Fleksibilan pristup učenju (mogućnost rada i studiranja usporedo) (Hirschheim, 2005.); (Illinois Online Network, 2003.); (Kyong-Jee, 2005.) ▪ Smanjenje troškova obrazovanja (Bates, 2004.); (Horton, 2000.); (Rosenberg, 2001.) ▪ Povećanje udjela visokoobrazovanog kadra (Bates, 2004.) ▪ Odgovor na “imperativ” tehnologije (Bates, 2004.) 	<ul style="list-style-type: none"> ▪ Rizik od neisplativosti ulaganja ▪ Problem priznavanja takvog načina obrazovanja i stečene diplome (Bates, 2004.) ▪ Opasnost od lakog načina stjecanja diplome, bez stjecanja znanja adekvatnog stečenoj diplomi (Bates, 2004.) ▪ Odmicanje od tradicionalnih sveučilišnih vrijednosti (Bates, 2004.) ▪ Opasnost od personalne (osobne) izolacije (Horton, 2000.)

2.2. Problemi i izazovi uvođenja e-učenja u visoko školstvo

U posljednjih dvadesetak godina, mnoga sveučilišta integrirala su neki od oblika e-učenja u procese učenja i podučavanja studenata. Unatoč prednostima koje su postignute uvođenjem e-učenja, problem se odnosi na način na koji je e-učenje implementirano, a to je tzv. „*bottom-up*“ pristup kojim se izbjeglo strateško planiranje uvođenja e-učenja u visoko školstvo. Implementacija e-učenja se provodila bez strateškog plana i bez stvaranja potrebnih preduvjeta za strateško uvođenje e-učenja u postojeću praksu i obrazovnu strukturu sveučilišta (Collis & Van der Wende, 2002.).

Uvođenje e-učenja u institucije visokog školstva bilo je više evolucija, nego revolucija (Boezerooij, 2006.) u kojoj su tzv. „samostalni strijelci“ neuspješno pokušavali pokrenuti revoluciju. Samostalni strijelci su nastavnici koji samostalno uz malu potporu razvijaju gradivo podržano tehnologijama (Bates, 2004.).

Dodjeljivanje male financijske potpore nastavnicima za uvođenje tehnologija ima prednosti, ali i nedostataka. Mnoge nastavnike može potaknuti na uporabu tehnologije te ih motivirati na razvoj vještina korištenja tehnologije. Nastavnicima se modelom samostalnog strijelca osigurava

autonomija u odlučivanju o metodama nastave i na taj način one postaju dio kulture na sveučilištu. Međutim, model samostalnog strijelca može dovesti do neujednačenosti i amaterizma u području dizajna i proizvodnje nastavnog materijala. Mnogi projekti samostalnog strijelca nikada ne završe, a nastavnici troše mnogo vremena na projekt koji ne pokazuje završne rezultate. I ono najvažnije, da bi se mogle opravdati i dokazati prednosti uporabe tehnologije, njena primjena mora biti popraćena reorganizacijom nastavnog procesa koja mora biti strateški definirana, a kod samostalnih strijelaca to nije slučaj.

Visoko obrazovanje je danas postalo dio globalnog pokreta prema novom načinu stvaranja i korištenja znanja. Nov način je fokusiran na rješavanje problema, osjetljiv je na potrebe korisnika, ulaže velike napore u kvalitetu i kvantitetu te prelazi granice na putu prema interdisciplinarnosti. U ekonomiji temeljenoj na znanju, vlada gleda sveučilišta kao pokretače društvenih promjena te ekspanzije napretka. Biti konkurentan na svjetskom tržištu, danas znači ulagati u visoko obrazovanje. Paralelno s ulaganjem države u visoko obrazovanje, sveučilišta moraju sama pronalaziti dodatna nevladina sredstva financiranja. Institucije koje su donedavno bile okrenute isključivo prema svoje tri primarne funkcije: podučavanju, istraživanju i služenju društvu, sada se moraju okrenuti poduzetništvu i komercijalizaciji. Od nastavnika se traži da rade i ostvaruju više s manje resursa: da podučavaju sve veći broj studenata, da vode više istraživanja, da publiciraju velik broj znanstvenih i stručnih radova, da postižu vrijedne znanstvene rezultate, ali i da privređuju dodatna sredstva za sveučilište. Studenti s druge strane zahtijevaju sve više, odrastaju spojeni na Internet 24 sata dnevno, 7 dana tjedno te su uz takvu dostupnost znanja i informacija sve više zahtjevniji i kritičniji prema nekvalitetnom podučavanju i nekompetentnosti nastavnika.

U novonastalim uvjetima, primjena informacijsko-komunikacijske tehnologije u visokom obrazovanju je nezaobilazna. Koraci uvođenja novih tehnologija u visoko obrazovanje su (Collis & Moonen, 2001.) (Slika 2-1.):

1. **Predinicijalizacija i inicijalizacija** u kojoj se aktivnosti odvijaju pretežito kroz „bottom-up“ pristup,
2. **Implementacija** u kojoj je razvijen strateški pristup,

3. **Institucionalizacija** u kojoj su promjene integrirane u ključne procese u institucijama visokog školstva.



Slika 2-1. Koraci uvođenja novih tehnologija u visoko obrazovanje

Današnje stanje pokazuje pomak visokoškolskih institucija prema naprijed, sve više visokoškolskih institucija prelazi iz faze inicijalizacije u fazu implementacije, pa čak i u fazu institucionalizacije. Smith (Smith, 2005.) navodi da je u europskom visokom školstvu vidljiv pomak od individualno potenciranih tehnoloških inovacija prema sustavskim i političkim modelima uvođenja novih tehnologija u koje spada i e-učenje. U rezultatima istraživanja koje je provela OECD organizacija, navodi se da je postala uobičajena praksa da sveučilišta kreiraju strategiju za uvođenje e-učenja (OECD, 2005.). Collis i Van der Wende (2002) navode da bi za potpunu institucionalizaciju ICT-a, trebalo uspostaviti snažnu tehnološku infrastrukturu, na pedagoški način koristiti postavljenu infrastrukturu, te razviti strateške planove za uvođenje i primjenu ICT-a i e-učenja u visoko školstvo.

2.3. Pregled važnijih istraživanja o strateškom pristupu u uvođenju e-učenja u visoko školstvo

Strateško planiranje uvođenja e-učenja u visoko školstvo predmet je interesa većeg broja istraživača. Primjena višekriterijskog odlučivanja u strateškom planiranju uvođenja e-učenja nova je i neistražena. Modeli za višekriterijsko odlučivanje koji služe kao modeli za donošenje odluke o uvođenju e-učenja u visoko školstvo, po prvi se puta sustavno u okviru istraživanja obuhvaćenog ovom doktorskom disertacijom, primjenjuju kao potpora u rješavanju problema strateškog planiranja uvođenja e-učenja. Pregled istraživanja i primjena metoda višekriterijskog

odlučivanja (Analitički hijerarhijski proces i Analitički mrežni proces) bit će detaljnije opisani u poglavljima 5.1. i 6.1.

U nastavku su izdvojena neka od važnijih istraživanja vezana za strateško planiranje uvođenja e-učenja u visoko školstvo.

Wills i Yetton su se 1997. godine (Wills & Yetton, 1997.) bavili strateškim pristupom u uvođenju informacijsko-komunikacijske tehnologije te su nastojali klasificirati strategije za uvođenje ICT-a u visoko školstvo. Analizirali su proces uvođenja ICT-a u odnosu na strategije, znanja i vještine, menadžerske procese i strukturu institucije. U istraživanju je sudjelovalo 20 sveučilišta, a strategije koje su izdvojili kao tri osnovne u uvođenju informacijsko-komunikacijske tehnologije u visoko obrazovanje su: strategija dodanih vrijednosti (engl. *value added strategy*), strategija temeljena na troškovima (engl. *cost-based strategy*) i hibridna strategija.

Tony Bates (Bates, 2000.) je 2000. godine objavio knjigu strategija za vodstvo sveučilišta pod nazivom „*Managing technological change: strategies for college and university leaders*“ u kojoj je iznio niz preporuka za što uspješnije donošenje strateških odluka i upravljanje sveučilištem. Autor odgovara na pitanje što sve treba učiniti kako bi se reorganizacijom, restrukturiranjem ili reinženjeringom sveučilišta i fakulteta osigurala uspješna i financijski isplativa primjena novih tehnologija. Rezultati njegova istraživanja obuhvaćaju niz strategija za planiranje i upravljanje te organizacijskih strategija za uvođenje novih tehnologija. T. Bates navodi i moguće implikacije restrukturiranja sveučilišta.

Isti autor objavio je rezultate svojih istraživanja i u publikaciji „*National strategies for e-learning in post-secondary education and training*“ (Bates, 2001.) namijenjenoj stručnjacima koji se bave strateškim planiranjem u obrazovanju i vladinim službenicima i političarima koji trebaju razumjeti strateško planiranje u obrazovanju i uspješno ga povezivati s nacionalnim razvojem.

Petra Fisser (Fisser, 2001.) opisuje promjene koje nastaju u visokom školstvu uvođenjem informacijsko-komunikacijske tehnologije, s naglaskom na e-učenje. Istraživanje autorice je trajalo četiri godine i obuhvatilo je analizu slučajeva 5 europskih sveučilišta. Rezultati

istraživanja dali su odgovor na primarno istraživačko pitanje: „Koje organizacijske teorije mogu pomoći u razumijevanju novonastalih promjena u visokom obrazovanju i kako te teorije mogu biti primijenjene u odlučivanju o novim oblicima učenja koji se uvode u visoko školstvo?“.

Scott Howell, Peter Williams i Nathan Lindsay (Howell, 2003.) u zajedničkoj publikaciji „*Thirty-two trends affecting distance education*“ navode 32 trenda koja utječu na strateško planiranje uvođenja e-učenja. Autori smatraju da dugoročne demografske i ekonomske projekcije na koje se često oslanja strateško planiranje, nisu dovoljne za uspješno planiranje uvođenja e-učenja, pa su definirali trendove vezane uz napredovanje tehnologije, stilove učenja, reakcije nastavnika i studenata, tenzije između administrativne podrške, nastavnog osoblja te uprave visokoškolskih institucija, organizacijsku kulturu i dr. Trendovi su organizirani u nekoliko kategorija: trendovi vezani uz studente, fakultetski trendovi, akademski trendovi, tehnološki trendovi, ekonomski trendovi, trendovi učenja na daljinu i trendovi vezani uz viziju. Svi trendovi su identificirani na temelju opsežnog pregleda literature iz područja e-učenja, a definirani su s ciljem da donositeljima odluke pomognu u strateškom planiranju i donošenju odluke o uvođenju e-učenja na visokoškolske institucije.

Chris Curran (Curran, 2004.) u svojem istraživanju pod nazivom „*Strategies for e-learning universities*“ analizira strategije e-učenja različitih sveučilišta sa sljedeće tri perspektive: veće dostupnosti obrazovanja, povećanja kvalitete učenja i podučavanja i smanjenje troškova obrazovanja. Analiza slučajeva je provedena na europskim i američkim sveučilištima.

Benedetto Lepori (Lepori, 2004.) je sa svojim timom napravio pregled modela i strategija primjene e-učenja na Sveučilištima u Švicarskoj i Sveučilištima smještenim u tzv. pokrajini „Četiri motora Europe“. Njihova analiza je bila fokusirana na četiri osnovne dimenzije: racionalan pristup u uvođenju e-učenja, organizacija aktivnosti, sveučilišni centar za e-učenje i korisnici privučeni e-učenjem.

James Aczel, Olivier Cotinat, Pascale Hardy (Aczel, 2006.) te ostali koautori proveli su vrlo važno istraživanje čije rezultate su predstavili na četvrtoj EDEN-ovoj istraživačkoj radionici koja se održala u Barceloni, 2006 godine. U svojem istraživanju, autori su odgovorili na dva osnovna

pitanja: 1.) Kako se mogu identificirati inovacije u strategijama e-učenja visokoškolskih institucija? i 2.) Koji su kritični faktori uspjeha strategija e-učenja?. Istraživanje je provedeno na 25 visokoškolskih institucija. Rezultati su pokazali da većina institucija ima primjenu hibridnog učenja i da samo manji dio institucija posjeduje formalno donesen strateški dokument za uvođenje e-učenja. Kao kritični faktori uspjeha izdvojeni su: poslovni plan, proces upravljanja kvalitetom, centar podrške studentima te tehnologija koja je robusna, dostupna i jednostavna za korištenje uz adekvatnu tehničku podršku.

Boezerooij (Boezerooij, 2006.) se u svojoj doktorskoj disertaciji „*E-learning strategies of higher education institutions*“ bavi utvrđivanjem razlikovanja institucija visokog školstva s obzirom na strateški pristup koji one koriste u integraciji novih tehnologija u obrazovanje i tehničku i administrativnu podršku. Rezultati njegova istraživanja su pokazali da je osnovna prednost e-učenja fleksibilnost i dostupnost obrazovanja, te da su sveučilišta prvenstveno zainteresirana za stratešku primjenu e-učenja kako bi privukli što više studenata i u konačnici ostvarili veći prihod.

U ovom poglavlju izdvojena su samo neka istraživanja u području strateškog planiranja uvođenja e-učenja. U svakom od istraživanja prepoznati su reprezentativni rezultati, ali ukoliko napravimo presjek rezultata istraživanja, možemo tvrditi da su gotovo svi rezultati ukazali na važnost izrade strateških odrednica za uvođenje e-učenja u razvojnim planovima institucija.

3. STRATEŠKI PRISTUP I DONOŠENJE ODLUKE O UVOĐENJU E-UČENJA U VISOKO ŠKOLSTVO

E-učenje je snažan alat za postizanje strateških ciljeva sveučilišta. Ono doprinosi ostvarenju ciljeva na razini institucije i na osobnoj razini nastavnika i studenata. E-učenje mora biti na pomno planiran način integrirano u obrazovni sustav s namjerom da se unaprijedi učenje, podučavanje, istraživanje i poslovanje (Divjak & Begicevic, 2006.). E-učenje je katalizator promjena koji podupire razvoj znanja i vještina koje su potrebne u društvu znanja, a to su prikupljanje, analiza te kvalitetna primjena prikupljenih informacija i razvoj različitih metoda učenja kao što su upravljanje informacijama, kreativno mišljenje, kritičko mišljenje, rješavanje problema te kolaborativno učenje (Divjak & Begicevic, 2006.).

Svako sveučilište ima tri osnovne misije (Bates, 2005.):

1. podučavanje,
2. istraživanje i
3. služenje društvu.

Sa aspekta prve misije sveučilišta: podučavanja, e-učenje doprinosi provedbi Bolonjskog procesa i podizanju kvalitete učenja i podučavanja. Bolonjski proces je u hrvatskim uvjetima doveo do identifikacije loših aspekata postojećeg stanja u visokom školstvu: nedovoljno prostora, premali broj nastavnika, nemogućnost kvalitetnog praćenja nastave, sve veći broj obeshrabrenih studenata, izuzetno veliki postotak studenata koji ne završavaju započete studije i dr. Promjene obuhvaćene Bolonjskim procesom će se nakon prve faze, koja se uglavnom odnosila na promjenu strukture studija, nastaviti u smislu poboljšanja uvjeta i kvalitete učenja i podučavanja. U procesu „bolonjizacije“, e-učenje može pomoći u ostvarenju boljih uvjeta studiranja, na način da doprinosi efikasnijem učenju i podučavanju, da dopunjuje prostorne aspekte komunikacije na daljinu i smanjuje pojedine stavke u troškovima studiranja (Bilten EQIBELT, 2007.).

Uloga e-učenja prepoznata je u okviru Bolonjskog procesa i na europskoj razini. Jedan od ciljeva Europskog rektorskog seminara pod nazivom “Utjecaji Bolonjskog procesa na informacijsku

tehnologiju na europskim sveučilištima”, kojeg je organizirala organizacija EUA (*European University Association*), bio je pronaći odgovore na sljedeća pitanja (EUA, 2006.):

- Kako učenje na daljinu može pomoći studentima da slušaju nastavne module na različitim sveučilištima? i
- Kako hibridno učenje može pomoći da se isti nastavni moduli podučavaju dva puta u akademskoj godini, kako studenti ne bi gubili dodatnu godinu za prikupljanje potrebnih ECTS bodova iz razloga što nastavno osoblje nije u mogućnosti fizički držati module dva puta u akademskoj godini?

Istraživanje kao druga misija sveučilišta mora biti ugrađena u podučavanje, dok podučavanje treba motivirajuće utjecati na istraživanje. Sve više metodologija učenja i podučavanja i alata e-učenja, podupire tu paradigmu.

Sa aspekta treće misije sveučilišta: služenje društvu, sveučilište mora respektirati i principe tzv. „poduzetničkog sveučilišta“. Sveučilišta trebaju služiti društvu, doprinositi konkurentnosti visokoobrazovanog kadra, povećavati zapošljivost i znanstvenu komunikaciju te omogućiti građanima cjeloživotno obrazovanje.

Primjena e-učenja unapređuje obrazovni i istraživački proces te otvara vrata boljoj suradnji sveučilišta i društvenog okruženja. Iz tog razloga je od posebne važnosti da e-učenje bude strateški pozicionirano kao dio ukupnih promjena na sveučilištima te da bude dobro povezano s obrazovnim, znanstvenim te drugim ciljevima sveučilišta. Donošenje odluka o uvođenju pravog oblika e-učenja također je od velikog značaja kako bi se implementirao oblik koji je primjeren stvarnim uvjetima i potrebama sveučilišta, fakulteta, katedre i kolegija.

3.1. Strateški pristup u uvođenju e-učenja u visoko školstvo

Strateško planiranje je jedan od preduvjeta uspješnog i efikasnog razvoja organizacije. Putem strateškog planiranja se ciljevi, politike i poslovne aktivnosti organizacije integriraju u povezanu cjelinu.

Važnost strateškog planiranja je u sustavnom načinu donošenja strateških odluka, određivanju taktike i provođenju akcija koje trebaju oblikovati i voditi organizaciju prema budućnosti, slijedeći viziju definiranjem ciljeva, putova i načina djelovanja.

Prema Mintzbergu (Mintzberg, 1998.), strategija je poveznica između organizacije i okruženja, skup smjernica kojima se nastoje fokusirati naponi, definirati organizacija i osigurati konzistentnost. Pri kreiranju strategije, potrebno je sagledati prošlost, sadašnjost i budućnost. Strategija se može definirati i kroz pet sljedećih pristupa: strategija kao plan, strategija kao predložak, strategija kao položaj, strategija kao perspektiva i strategija kao posao (Mintzberg, 1998.).

Strategija obuhvaća dugoročne, buduće planove organizacije kojima se nastoje ostvariti ciljevi organizacije u postojećem konkurentnom okruženju. Strateški menadžment podrazumijeva skup odluka koje su donesene i skup aktivnosti koje su izvršene kako bi se realizirali planovi za postizanje ciljeva organizacije (Pearce & Robinson, 2007.).

Strategija mora stvoriti pretpostavke organizaciji za opstanak u dugom roku. Ona treba permanentno stvarati uvjete da organizacije ne budu ograničene u razvoju vlastite konkurentnosti i u svojim inovativnim procesima (Tipurić, 2002.).

Implementacija e-učenja je kompleksan i zahtjevan proces koji zahtjeva političke, društvene, organizacijske i tehnološke promjene. Detaljno razrađen plan strateškog djelovanja i aktivnosti, nužan je kako bi se te promjene i ostvarile.

Važnost strateškog planiranja u procesu uvođenja e-učenja opisana je u poglavlju 3.1.1., dok su u poglavlju 3.1.2. opisani važniji koraci koji su prethodili sustavnoj primjeni e-učenja u visokom školstvu.

3.1.1. Važnost strateškog pristupa u uvođenju e-učenja u visoko školstvo

Uvođenje e-učenja u visokoškolske institucije dio je šireg procesa promjena kojima se nastoje stvoriti uvjeti za kvalitetnu modernu sveučilišnu nastavu koja će omogućiti lakšu integraciju hrvatskog visokoškolskog obrazovnog sustava u europski prostor visokog obrazovanja.

Strateški pristup u uvođenju e-učenja, bitan je iz dva osnovna razloga (Boezerooij, 2006.):

1. omogućuje sustavno integriranje e-učenja u primarne (*core*) procese učenja i podučavanja i
2. e-učenje igra vrlo važnu i snažnu ulogu u pozicioniranju visokoškolskih institucija u sve konkurentnijem okruženju.

Svako sveučilište i/ili fakultet trebalo bi imati formalno donesenu strategiju uvođenja e-učenja koja mora uključivati:

- misiju,
- viziju,
- ciljeve sveučilišta te
- plan aktivnosti s eksplicitno određenim vremenskim okvirima.

Odlučivanje o uvođenju e-učenja treba delegirati na određene razine odgovornosti u sveučilišnoj hijerarhijskoj strukturi i time osigurati prisutnost i rješavanje problematike e-učenja na strateškim razinama odlučivanja.

Uvođenje e-učenja u visoko obrazovanje može se sagledavati na više razina: državnoj, sveučilišnoj, fakultetskoj i osobnoj (Divjak & Begicevic, 2006.). Postoje određeni problemi i izazovi na svakoj od navedenih razina.

Izazovi uvođenja e-učenja na državnoj razini su (Divjak & Begicevic, 2006.):

- Potreba za “čvrstom strategijom” (planiranje resursa),
- Fond za razvoj obrazovanja (povezan sa sveučilišnim i fakultetskim fondovima),
- Globalna infrastruktura za e-učenje,
- Motivacija za visokoškolske institucije, profesore i studente da koriste e-učenje,
- Zaštita intelektualnog vlasništva,
- Standardizacija.

Važnost strateškog pristupa u uvođenju e-učenja na državnoj razini je velika kako bi se savladali izazovi uvođenja e-učenja. Država kao važan sudionik u procesu obrazovanja treba dati svoj doprinos u uvođenju i primjeni e-učenja. Doprinos države očekuje se u sljedećim područjima:

- osiguravanje globalne infrastrukture i tehnološke potpore,
- kreiranje resursno provedive strategije za razvoj cjelokupnog obrazovnog sustava,
- uspostavljanje fonda za razvoj obrazovanja na nacionalnoj razini i
- uspostavljanje sustava motivirajućih mjera na nacionalnoj razini za poticanje visokoškolskih institucija, nastavnika i studenata na uvođenje i primjenu e-učenja.

Na sveučilišnoj razini, glavni je izazov kreiranje sveučilišne strategije za uvođenje e-učenja. Strategija uvođenja e-učenja može biti dio sveobuhvatne strategije sveučilišta ili može biti zaseban dokument kojim se definiraju strateške smjernice za uvođenje e-učenja.


Rezultati istraživanja koje je provedeno 2004. godine na 122 ispitanika (predstavnik institucija) iz 12 zemalja, pokazalo je da polovica sveučilišta ima strategiju e-učenja kao zasebni dokument, dok polovica sveučilišta ima strategiju za uvođenje e-učenja integriranu u neku drugu strategiju Sveučilišta (Observatory of Borderless Higher Education, 2006.). Gotovo sve institucije u OECD/CERI organizaciji (*Organisation for Economic Co-operation and Development*) također su potvrdile da imaju strategiju e-učenja ili su u postupku njenog kreiranja, samo njih 9 % je indiciralo da nemaju nikakav oblik strategije e-učenja niti su u postupku njenog kreiranja. Vidljiv je napredak od 2002. godine kada je postotak institucija koje nisu imale nikakav oblik strategije e-učenja niti su bile u postupku njenog kreiranja bio duplo veći, odnosno kada je iznosio 18% (OECD, 2005.). EUA također daje pregled strategija za uvođenje e-učenja i/ili uvođenje informacijsko-komunikacijske tehnologije na visokoškolske institucije (EUA, 2006.). Coimbra grupa u HECTIC izvještaju daje uvid u strateške pristupe uvođenja e-učenja koji su temeljeni na primjerima najbolje prakse (Coimbra group, 2002.).

Na fakultetskoj razini, uvođenje e-učenja mora biti usko povezano s misijom fakulteta, ali i strategijom sveučilišta. Prvi korak uvođenja mora biti analiza potreba provedena primjenom jedne ili više metoda kao što su: snimanje stanja, analiza podataka, SWOT analiza (analiza snaga,

slabosti, prilika, prijetnji), BSC (*Balanced scorecard*), AHP (Analitički hijerarhijski proces), ANP (Analitički mrežni proces) i dr. (Divjak & Begicevic, 2006.). Postupak strateškog planiranja i kreiranja strategije koja u sebi sadrži jasno definiranu misiju, viziju, ciljeve te indikatore uspjeha, korak je od ključne važnosti za uspješnu implementaciju e-učenja na fakultetskoj razini.

Nastavnici prilikom izrade nastavnih materijala trebaju na raspolaganju imati podršku eksperata za tehnološki, tehnički te pedagoški dio. E-kompetencije više ne smiju biti osobno pitanje nastavnika i studenata, već interes institucije pa se danas govori u kontekstu institucijskih e-kompetencija. S druge strane, e-učenje zahtjeva motiviranog i nezavisnog studenta koji ima dobru sposobnost navigacije i iskustvo u korištenju informacijsko-komunikacijske tehnologije i online nastavnih materijala.

Fakulteti trebaju strateški planirati i definirati potrebnu tehnološku, tehničku i pedagošku potporu, kako bi riješili probleme vezane uz uvođenje e-učenja. Potrebe koje trebaju biti zadovoljene kako bi se uspješno pratio put prema inovacijama pa tako i implementaciji e-učenja, prikazane su na slici 3-1. Ako se želi uspješno ulagati u istraživanje i razvoj potrebno je u potpunosti razumjeti proces uvođenja inovacija i potrebe koje se javljaju kroz vrijeme procesa uvođenja. Prvo se javlja potreba za ekspertima najviše razine u interesnom području, zatim potreba za komercijalnim „znati-kako“ pristupom i na kraju potreba za snažnim kulturnim „znati-kako“ pristupom (Slika 3-1.).



Slika 3-1. Potrebe pri uvođenju e-učenja na fakultetsku razinu (prilagođeno prema Markkula, 2002.)

3.1.2. Stanje e-učenja u visokom školstvu u Hrvatskoj

Važniji pomaci u primjeni e-učenja u visokom školstvu u Hrvatskoj dogodili su se u posljednjih desetak godina.

CARNet (CARNet, Hrvatska akademska i istraživačka mreža, 2006.) je učinio niz koraka kako bi se akteri hrvatskog obrazovnog sustava upoznali s e-učenjem i kako bi se s vremenom ono udomaćilo u hrvatskom školstvu. U nastavku ću ukratko opisati samo neke od njih, za koje smatram da su bili i još uvijek jesu, važniji pokretači uvođenja e-učenja u visoko školstvo.

CARNetov edukacijski centar Edupoint (Edupoint, Edupoint edukacijski centar, 2000.) osnovan je u prosincu 2000. godine i svojim korisnicima u posljednjih osam godina pruža sustavnu edukaciju iz područja informacijsko komunikacijske tehnologije i njene primjene, a posebno iz područja e-učenja i mrežnih tehnologija. Edupoint ujedinjuje različite edukacijske programe,

prvenstveno za članove akademske i istraživačke zajednice u Hrvatskoj, ali svojim uslugama je otvoren i za druge skupine korisnika.

Usluga koje nudi Edupoint su (Edupoint, 2000.):

- Online tečajevi - za studente, profesore i znanstvenike,
- E-learning akademija - za sve osobe zainteresirane za pokretanje, razvijanje ili implementaciju e-learning programa,
- E-learning radionice - za sve osobe zainteresirane za e-learning,
- E-student, Tečajevi o Internetu - za studente,
- E-profesori i znanstvenici, Program za primjenu ICT-a - za nastavnike u visokoškolskim učilištima i znanstvenike,
- Edupoint CNSI, Obrazovanje CARNetovih sistem inženjera - za CARNetove sistem inženjere,
- Edupoint CAMT, Cisco Akademija Mrežnih Tehnologija - za sve osobe zainteresirane za mrežne tehnologije,
- Edupoint časopis o primjeni informacijskih tehnologija u obrazovanju,
- Edulab,
- E-alat, podrška korisnicima WebCT alata za učenje na daljinu.

E-learning akademija (ELA, 2001.) jedna je od važnijih usluga koju pruža Edupoint. Inicijativa za pokretanje E-learning akademije razvijala se u razdoblju od 2001. do 2003. godine. CARNet je preko nekoliko projekata tada aktivno djelovao na području edukacije, podrške i informiranja o e-učenju. Projekti koji su u tom razdoblju vođeni u CARNetu (online tečaj za obrazovanje predavača, edukacijski materijali za podučavanje na CISCO akademiji, pilot projekt online tečaja o HTML-u i dr.), bili su pokazatelji da je došlo vrijeme u kojem se uočava potreba za sustavnim stjecanjem obrazovanja o e-učenju. Uspostava i djelovanje E-learning akademije rezultat je zajedničke suradnje nekoliko timova. CARNetov projektni tim i ekspertni tim s kanadskog Sveučilišta Britanska Kolumbija surađuju pri izradi programa i izvođenju nastave. ELA preko svojih programa razvija stručnjake u Hrvatskoj i regiji koji potiču i primjenjuju e-učenje u svojoj okolini. Ona kontinuirano razvija i radi na unapređenju kvalitete programa, usklađujući ih s globalnim *up-to-date* znanjem s područja e-učenja, prilagođava programe ciljanim polaznicima i

njihovim potrebama i pruža kvalitetnu uslugu udaljenim polaznicima i predavačima kroz osiguranje kvalitetne organizacije, održavanje kompetencija svih učesnika u poslovnom procesu kroz suradnju s vrhunskim svjetskim i domaćim partnerima.

S ciljem da e-učenje dugoročno zaživi, CARNet je pokrenuo i projekt „Uspostava referalnih centara za podršku nastavnicima za primjenu IT-a u nastavi“. U 2003. godini pokrenuto je sedam referalnih centara za pružanje podrške sveučilišnim nastavnicima u primjeni IT-a u nastavi (Referalni centri za e-obrazovanje, 2006.):

- RC za odabir alata za e-obrazovanje, Fakultet elektrotehnike i računarstva, Zagreb, voditelj: Kristijan Zimmer
- RC za izradu obrazovnih materijala, Tekstilno - tehnološki fakultet, Zagreb, voditelj: prof. dr. sc. Goran Hudec
- RC za odabir računalne i programske podrške u e-obrazovanju, Sveučilišni računski centar, Zagreb, voditelj: Vladimir Braus
- RC za prijavljivanje projekata e-obrazovanja, Fakultet organizacije i informatike, Varaždin, voditelj: prof. dr. sc. Blaženka Divjak
- RC za izradu multimedijalnih elemenata i njihovu prilagodbu za WWW, Grafički fakultet, Zagreb, voditelj: prof. dr. sc. Karolj Skala
- RC za metodiku i komunikaciju u obrazovanju na daljinu, Fakultet organizacije i informatike, Varaždin, voditelj: doc. dr. sc. Goran Bubaš
- RC za samoprocjenu i procjenu znanja u e-obrazovanju, Medicinski fakultet, Zagreb, voditelj: prof. dr. sc. Milan Taradi

Korisnicima se preko osnovanih referalnih centara, nastojala osigurati kontinuirana podrška u edukacijskom, savjetodavnom, tehničkom, financijskom i organizacijskom smislu. Projekti su završeni, ali neki referalni centri još uvijek pružaju usluge i informacije korisnicima, iako je financijska podrška obustavljena.

Osim referalnih centara, u sustavu podrške Edupointa važno je spomenuti i uslugu osiguravanja licenci, podrške i pružanja edukacije o uporabi alata za e-učenje, koju mogu koristiti svi nastavnici u hrvatskoj akademskoj zajednici.

Vrlo važan korak u standardizaciji uvođenja e-učenja u visoko školstvo, napravio je CARNet s kreiranjem dokumenta „Standardizacija i valorizacija digitalnih obrazovnih materijala“ (Standardizacija i valorizacija digitalnih obrazovnih materijala, 2005.) u svibnju 2005. godine. Na zahtjev Ministarstva znanosti i tehnologije i Sveučilišta u Zagrebu, CARNet je okupio tim stručnjaka koji su kreirali dokument u kojem je dana tehnička podloga za rješavanje pitanja normizacije, pohranjivanja, kategorizacije i vrednovanja digitalnih obrazovnih sadržaja. U dokumentu je napravljena kategorizacija digitalnih obrazovnih materijala, dan je prijedlog primjene standarda u produkciji digitalnih obrazovnih materijala, izrađena je specifikacija repozitorija digitalnih obrazovnih materijala, prijedlog uporabe softvera prilikom izrade i primjene digitalnih obrazovnih materijala te prijedlog postupka recenzije instruktorskog dizajna. Dokument "Standardizacija i valorizacija digitalnih obrazovnih materijala" ostao je samo interni dokument koji nije formalno prihvaćen, ali je poslužio kao vrijedan doprinos u kreiranju strategije e-učenja Sveučilišta u Zagrebu. Posebni doprinos ovaj bi dokument mogao dati u postupku recenziranja materijala e-učenja koje provode sveučilišna povjerenstva za znanstvenu i nastavnu literaturu (Divjak & Prišćan, 2005.).

CARNet je navedenim projektima poticao uvođenje e-učenja u visokoškolske institucije, no nažalost bez formalne podrške sveučilišta i države, odnosno bez jasno definiranog strateškog okvira na državnoj i sveučilišnoj razini. CARNet je dao veliku potporu tzv. „usamljenim jahačima“ ili „samostalnim strijelcima“ koji su hrabro uveli e-učenje u nastavu na svojim fakultetima, ali tako nastali *bottom-up* pristup nije jamčio dugoročne rezultate. S druge strane, CARNet je osigurao dio preduvjeta nužnih za strateško uvođenje e-učenja u visoko školstvo.

Strateško planiranje uvođenja e-učenja u hrvatsko visoko školstvo započinje s TEMPUS projektom EQIBELT: *Education Quality Improvement by E-Learning Technology* (Poboljšanje kvalitete obrazovanja primjenom tehnologija e-učenja) (Tempus EQIBELT, 2006.) koji je pokrenut u 9. mjesecu 2005. na zajedničku inicijativu Sveučilišta u Zagrebu, Rijeci i Dubrovniku, zajedno s konzorcijem sastavljenim od 13 institucija. Projekt koordinira Sveučilišni računski centar (SRCE) (Sveučilišni računski centar, 2006.). Trajanje projekta je 3 godine i za to vrijeme su zadani sljedeći ciljevi projekta:

- poboljšati kvalitetu sveučilišnog obrazovanja primjenom metoda i tehnologija e-učenja,

- izraditi i prihvatiti programski (strateški), formalnopravni i tehnološki okvir, te standarde za primjenu metoda i tehnologija e-učenja na visokim učilištima u Hrvatskoj, kroz prijenos i prilagodbu iskustava i znanja s Europskih sveučilišta,
- osmisliti i uspostaviti trajno održiv sustav centara potpore i mrežu stručnjaka za poticanje i potporu projektima e-učenja,
- praktično ostvariti i prikazati, te promovirati uspješne primjene metoda i tehnologija e-učenja kao alata za poboljšanje sveučilišnog obrazovanja.

Očekivani rezultati projekta su:

1. prihvaćanje vizije primjene e-učenja na svakom od hrvatskih sveučilišta - članova konzorcija,
2. strateški i provedbeni dokumenti vezani uz implementaciju e-učenja na svakom od sveučilišta,
3. minimalni tehnički standardi za projekte e-učenja na sveučilištima,
4. centri potpore projektima e-učenja na svakom od hrvatskih sveučilišta-članova konzorcija
5. pilot projekti u području primjene e-učenja.

Popis aktivnosti i vremenski plan njihova izvršenja u okviru EQIBELT projekta nalazi se u Tablici 3-1. (Bilten EQIBELT, 2005.).

Tablica 3-1. Popis aktivnosti i vremenski plan njihova izvršenja u EQIBELT projektu

Popis važnijih aktivnosti	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Q10	Q11	Q12
Izrada i prihvaćanje vizije e-učenja												
Izrada politika u području e-učenja												
Izrada standarda u području e-učenja												
Anketa o stanju e-učenja u RH												
Osmišljavanje sustava potpore												
Uspostava centara potpore e-učenju												
Pilot projekti												

Q = Kvartal

S obzirom da su prošle dvije godine otkada je projekt započeo, može se procijeniti da je većina aktivnosti izvršena po planu te da su planirani ciljevi realizirani ili su u postupku realizacije. Jedan od najvažnijih ciljeva: kreiranje sveučilišnih strategija za uvođenje e-učenja, je postignut. Više o strategiji u poglavlju 7.1.

Neki od očekivanih rezultata i planiranih aktivnosti ipak nisu ostvareni i provedeni u planiranim rokovima zbog više objektivnih i subjektivnih razloga. Jedna od planiranih aktivnosti bila je i anketa o stanju e-učenja u RH, koja nije provedena, a rezultati takvog anketiranja trebali su služiti kao vrlo važno polazište u kreiranju strategije e-učenja Sveučilišta u Hrvatskoj.

Vrlo značajni rezultati projekta su i radionice koje su se održale u 2006. godini i koje su uvelike doprinijele ostvarenju ciljeva projekta, a rasprave, preporuke i zaključci koji su doneseni na radionicama, poslužili su kao potpora izradi sveučilišnih strategija uvođenja e-učenja. To su bile sljedeće radionice:

1. Radionica «Vizija i strategija e-učenja u visokom obrazovanju u Hrvatskoj», održana na Sveučilištu u Dubrovniku u ožujku 2006.
2. Radionica «Organizacija Centara potpore e-učenju», održana u Cavtatu u sklopu ITI konferencije u lipnju 2006.
3. Radionica «Standardi i preporuke u području e-učenja», održana u Cavtatu u sklopu ITI konferencije u lipnju 2006.

Na radionici «Vizija i strategija e-učenja u visokom obrazovanju u Hrvatskoj» provedena je anketa čiji rezultati su bili podloga za istraživanje napravljeno u okviru ove doktorske disertacije, a poslužili su i za definiranje okvira strategije uvođenja e-učenja Sveučilišta u Zagrebu. Detaljnija kvalitativna analiza «Strategije e-učenja na Sveučilištu u Zagrebu» i usporedba s rezultatima istraživanja, napravljena je u poglavlju 7.1.

Anketa je provedena s ciljem prikupljanja stavova sudionika radionice o ulozi i ciljevima e-učenja i o kriterijima za odluku o implementaciji e-učenja. Anketu su provele prof.dr.sc. Blaženka Divjak i Nina Begičević (Bilten EQIBELT, 2006.).

Zaključci radionice proizašli su iz rasprava i predavanja, ali ponajviše iz rezultata ankete koji su bili prezentirani zadnjeg dana radionice (prezentatorice: prof.dr.sc. Blaženka Divjak i Nina Begičević).

Zaključci radionice «Vizija i strategija e-učenja u visokom obrazovanju u Hrvatskoj» bili su sljedeći (Bilten EQIBELT, 2006.):

- Pomak prema društvu znanja zahtijeva promjenu načina poučavanja i učenja,
- Na putu smo od učenja prema e-učenju i dalje prema novim oblicima učenja,
- E-učenje treba biti sastavnica cjelovitog akademskog (obrazovnog) plana,
- Iskorak prema e-učenju treba biti strateška, a ne tehnološka odluka,
- E-učenje kao jedan od načina poticanja i provođenja Bolonjskog procesa,
- E-učenje kao sveobuhvatni sveučilišni projekt – prilika za integraciju sveučilišta,
- Infrastruktura e-učenja trebala bi biti dio sveukupne sveučilišne ICT infrastrukture,
- Portal e-učenja kao jedinstveni studentski portal za učenje i sveučilišni život,
- Spremnost okoline i dostupnost održive i pouzdane podrške ključni su čimbenici za implementaciju e-učenja,
- Važnost programa usavršavanja nastavnika, mogućnost napredovanja i sustav nagrađivanja nastavnika koji se koriste e-učenjem,
- Implementacija e-učenja zajednička je zadaća vlade, sveučilišnih i fakultetskih uprava, nastavnika/profesora i studenata. Svi sudionici trebaju na svojim razinama odgovornosti na različite načine dati svoj doprinos u primjeni e-učenja.

Radionica o Centrima potpore e-učenju održana je u Cavtatu 20. i 21. lipnja 2006. s ciljem upoznavanja i rasprave o mogućim organizacijskim i financijskim modelima, potrebnim kompetencijama i mogućim uslugama takvog centra. Osnova radionice bila su predavanja predstavnika europskih sveučilišta o njihovu načinu potpore e-učenju i aktivnostima te organizaciji usluga, skupina i centara potpore e-učenju. Zaključci radionice «Organizacija Centara potpore e-učenju» bili su sljedeći (Bilten EQIBELT, 2006.):

- Centar potpore e-učenju treba osigurati multidisciplinarnu potporu nastavnicima i studentima,

- Važno je prepoznati specifične potrebe za potporu u području e-učenja na određenom sveučilištu/fakultetu/školi,
- Važno je odabrati odgovarajući organizacijski model za potporu e-učenju na određenom sveučilištu/fakultetu/školi,
- Potrebno je definirati specifične kompetencije i usluge centra potpore e-učenju na određenom sveučilištu/fakultetu/školi,
- Važno je stvoriti stvarne preduvjete za operativan, održiv i učinkovit rad centara potpore e-učenju,
- Sva postojeća i dostupna sredstva i pristupi na nacionalnoj, sveučilišnoj i fakultetskoj razini trebaju se iskoristiti za potporu e-učenju.

EQIBELT-ova radionica «Standardi i preporuke u području e-učenja», održana je u Cavtatu od 22. do 23. lipnja 2006. godine. Radionica se sastojala od pet predavanja istaknutih predavača suradnika projekta EQIBELT i stručnjaka s hrvatskih sveučilišta, a zaključci su temeljeni na definiranju sljedećih potreba i preduvjeta za uvođenje e-učenja (Bilten EQIBELT, 2006.):

- Potreba za odabirom i primjenom standarda u e-učenju,
- Potreba za zajedničkim repozitorijem sadržaja za e-učenje čija uspostava bi omogućila smanjenje troškova i trajanja izrade nastavnih materijala,
- Nužna standardizacija i odabir sustava i alata za e-učenje,
- Izrada preporuka i uputa kako trebaju izgledati nastavni materijali ili kako napraviti dobre nastavne materijale,
- Izrada obrazovnih portala koji bi studentima omogućili brže i jednostavnije pronalaženje željenih kolegija, a svima koji su uključeni u nastavni proces omogućila jednostavnije obavljanje administrativnih poslova,
- Potreba za definiranjem i objavom sučelja za razmjenu podataka između središnjih informacijskih sustava i aplikacija za e-učenje, kako bi se spriječilo nepotrebno višestruko upisivanje podataka, osigurala ažurnost i konzistentnost podataka te povećala produktivnost i olakšao rad studentima.

Zaključci doneseni na opisanim radionicama bili su ključni za ostvarenje ciljeva projekta EQIBELT. Rezultati ankete provedene na prvoj radionici projekta EQIBELT, bili su polazište za definiranje «Strategije e-učenja na Sveučilištu u Zagrebu».

3.2. Faze strateškog planiranja i donošenja odluke o uvođenju e-učenja

U procesu strateškog planiranja i donošenja odluke o uvođenju e-učenja možemo izdvojiti četiri osnovne faze (Dyer, 1991.): (1) faza istraživanja problema, (2) faza razvijanja i izgradnje modela, (3) faza donošenja odluka i (4) faza provođenja odluke. Četiri faze strateškog planiranja i donošenja odluke te metode koji su korištene u tim fazama prikazane su u tablici 3-2. Proces strateškog planiranja i donošenja odluke o uvođenju e-učenja može se raščlaniti i na veći broj faza (Slika 3-2.) (Markkula, 2002.):


1. Definiranje ciljeva i očekivanja (proces predviđanja),
2. Provedba pozadinske procjene (SWOT analiza),
3. Planiranje i priprema (analiza potreba, tehnike kreativnog mišljenja („oluja mozgova“), inovacije, predviđanja)
4. Kreiranje strategije uvođenja e-učenja (vizija, misija, ciljevi, plan aktivnosti)
5. Proces donošenja odluka (donošenje odluka na svim razinama odgovornosti)
6. Akcija, djelovanje (kolaboracija svih sudionika prema planiranim aktivnostima i definiranim razinama odgovornosti)
7. Nadgledanje, nadzor (evaluacijski proces, vrednovanje, ocjenjivanje)
8. Daljnji koraci (motivacija, entuzijizam).

U okviru ove doktorske disertacije istražene su mogućnosti korištenja matematičkih modela i statističkih tehnika u strateškom planiranju i donošenju odluka o uvođenju e-učenja u hrvatski visokoškolski sustav. Istraživanje koje je provedeno, prati četiri osnovne faze strateškog planiranja i donošenja odluke o uvođenju e-učenja, a svoj doprinos daje u prve tri faze (prema Tablici 3-2.).

Svaka od navedenih faza detaljnije je opisana u poglavljima 3.2.1. do 3.2.4.

Tablica 3-2. Četiri faze strateškog planiranja i donošenja odluke o uvođenju e-učenja (prilagođeno prema Dyer, 1991.).

FAZE	METODE
<p>1. Faza istraživanja problema Identifikacija centralnog problema odlučivanja</p> <ul style="list-style-type: none"> ▪ Analiza situacije i snimanje postojećeg stanja ▪ Pretraživanje ▪ Identifikacija problema ▪ Definiranje odgovornosti za problem ▪ Izvještaj o problemu 	<ul style="list-style-type: none"> • Prikupljanje podataka • Dohvat podataka • Pohranjivanje • Sistematiziranje • Analiza podataka
<p>2. Faza razvijanja i izgradnje modela Definiranje alternativa i kriterija te razvoj modela</p> <p>Traženje alternativa</p> <ul style="list-style-type: none"> ▪ Inicijalna lista ▪ Revidirana lista <p>Određivanje kriterija</p> <ul style="list-style-type: none"> ▪ Lista nužnih kriterija ▪ Lista pridodanih kriterija <p>Razvoj i izgradnja modela za višekriterijsko odlučivanje</p>	<ul style="list-style-type: none"> • Prikupljanje podataka • Dohvat podataka • Pohranjivanje • Sistematiziranje • Analiza podataka
<p>3. Faza donošenja odluka Ocjenjivanje (evaluacija) alternativa</p> <ul style="list-style-type: none"> ▪ Rezultati procesa odlučivanja ▪ Odabir alternative ▪ Analiza osjetljivosti 	<ul style="list-style-type: none"> • Prikupljanje podataka (procjena) • Analiza odlučivanja • Dohvat podataka (rezultata) • Analiza podataka • Sistematiziranje • Pohranjivanje
<p>4. Faza provođenja odluke Plan aktivnosti i sustav kontrole</p>	<ul style="list-style-type: none"> • Analiza odluke • Analiza podataka



Slika 3-2. Osam faza strateškog planiranja i donošenja odluke o uvođenju e-učenja (prilagođeno prema Markkula, 2002.)

3.2.1. Faza istraživanja problema

U fazi istraživanja problema provedena je analiza situacije i snimanje postojećeg stanja kako bi se precizno definirao centralni problem: potreba za strateškim planiranjem i donošenjem odluka u procesu uvođenja e-učenja u visoko školstvo u Hrvatskoj. Nakon što je problem identificiran, napravljen je i pregled ključnih faktora i trendova vezanih uz definirani problem (detaljnije u poglavljima 1, 2 i 3).

Metode analize situacije i snimanja stanja su od velike pomoći i važnosti u strateškom odlučivanju. Za strateško odlučivanje su vjerojatno najvažniji resursi informacije, a snimanje stanja se temelji na prikupljanju vrijednih informacija o postojećoj situaciji. Odnos između kvalitete informacija i kvalitete strateških odluka je proporcionalan. Snimanje stanja možemo definirati kao aktivnost prikupljanja informacija koja uključuje potpuno izlaganje informacijama i njihovu percepciju (Hough, 2004.), dakle snimanje stanja je metoda koju donositelji odluka koriste ne bi li prikupili informacije i na temelju njih donijeli što kvalitetnije odluke. Informacija je rezultat prikupljanja i obrade podataka koji dovodi do smanjenja neizvjesnosti. U znanstvenom smislu možemo reći da je informacija sve ono što smanjuje entropiju (entropija: mjerilo neuređenosti sustava) u nekom sustavu. U dinamičnoj okolini se uvijek traže dodatne informacije jer je i nesigurnost kod odlučivanja veća. Pri tome se misli na nesigurnost kao na razliku između obrađenih i potrebnih informacija odnosno na nemogućnost predviđanja posljedica donesene odluke (Frishammar, 2003.).

Postoje dva osnovna načina gledanja na prikupljanje informacija. S perspektive obrade informacija, dinamična okolina traži od donositelja odluke da prikupljaju dodatne informacije pomoću kojih tada formiraju glavna strateška pitanja i koriste ih kod odabira najbolje alternative. Dodatne informacije ubrzavaju proces odlučivanja. Promatrano s perspektive društvene spoznaje, razina snimanja se povećava u uvjetima nesigurnosti, ali samo do određenog praga, nakon kojeg počinje opadati. Razina snimanja je izrazito niska u ekstremnim uvjetima: uvjetima izrazito visoke i izrazito niske nesigurnosti.

Snimanje stanja obuhvatilo je prikupljanje i dohvaćanje potrebnih informacija koje su se zatim sistematizirale i pohranjivale. Informacije koje su se prikupljale bile su pretežito tzv. «meke» (engl. *soft*) informacije (Frishammar, 2003.). U meke informacije se ubrajaju subjektivne, kvalitativne i općenite informacije kao što su vizije, misije, ideje i razne druge kognitivne strukture. «Tvrde» (engl. *hard*) informacije su kvantitativne informacije, odnosno one koje se mogu dokazati, bilo matematički ili nekom drugom metodom.

Rezultati do kojih se došlo analizom situacije i snimanjem postojećeg stanja, kao i dokumenti i istraživanja koji su analizirani u fazi istraživanja problema, objašnjeni su u poglavljima 2, 3.1.1. i 3.1.2.

Nadalje, u postupku istraživanja se pokušao odrediti i stupanj odgovornosti za rješavanje problema koji leži na određenim institucijama, te je napravljena analiza svih koraka koje su odgovorne institucije do sada napravile i čiji rezultati su omogućili stvaranje preduvjeta za postupak strateškog uvođenja e-učenja u institucije visokog školstva (poglavljja 3.1.1. i 3.1.2.).

3.2.2. Faza razvijanja i izgradnje modela

U fazi razvijanja i izgradnje modela, pregledom mnogih znanstvenih i stručnih izvora, te primjera strategija e-učenja vodećih europskih sveučilišta i fakulteta (detaljnije u poglavlju 4.3.1.), identificirani su ciljevi i prednosti e-učenja te kriteriji za odlučivanje o uvođenju e-učenja u visoko školstvo. Na temelju identificiranih ciljeva, prednosti i kriterija, kreirana je anketa čiji cilj je bio prikupljanje podataka od ispitanika, koji su bili stručnjaci za e-učenje u visokom školstvu. Anketiranje je provedeno u svrhu potpore izradi strateških dokumenata uvođenja e-učenja u okviru Tempus projekta EQIBELT. Anketa je bila strukturirana na način da izvrši prikupljanje i prioritizaciju podataka potrebnih za izradu strateških dokumenata: ciljeva uvođenja e-učenja, prednosti uvođenja e-učenja i kriterija odlučivanja važnih za strateško planiranje uvođenja e-učenja (detaljnije u poglavlju 4.3.1).

Pilot istraživanje je provedeno na prvoj radionici projekta EQIBELT pod nazivom „*Creating University E-Learning Vision and Strategy*” koja je održana u Dubrovniku od 3. do 5. ožujka

2006. godine. Istraživanje su provele prof.dr.sc. Blaženka Divjak i autorica ove disertacije Nina Begičević. Kriteriji za odabir ispitanika bili su: ekspertiza u e-učenju i poznavanje učenja u okruženju visokog školstva. U anketiranju je sudjelovalo 33 ispitanika. Rezultati pilot istraživanja su objavljeni i prezentirani na konferenciji ITI 2006 (Divjak & Begicevic, 2006.).

Nakon radionice, u travnju i svibnju 2006. godine, skup anketiranih hrvatskih stručnjaka za e-učenje u visokom školstvu je proširen na 90 ispitanika (N=90). Detaljnije će o postupku anketiranja i o ispitanicima u istraživanju biti riječi u poglavljima 4.3.2. i 4.3.3., a u Prilogu 1 nalazi se popis ispitanika koji su sudjelovali u istraživanju.

Rezultati anketiranja su obrađeni metodama deskriptivne statistike (aritmetička sredina, medijan, mod, standardna devijacija, varijanca, koeficijent varijacije, raspon) te se deskriptivnom obradom rezultata došlo do ocjena važnosti ciljeva i prednosti e-učenja te ocjena važnosti kriterija za odlučivanje kod uvođenja e-učenja (detaljnije u poglavlju 4.4.1.).

Rezultati anketiranja su u sljedećoj iteraciji obrađeni faktorskom analizom koja je reducirala skup definiranih kriterija odnosno smanjila broj varijabli na manji broj faktora. Osnovni cilj primjene faktorske analize bila je potreba za racionalizacijom, reduciranjem ili tzv. „pročišćavanjem“ skupa identificiranih kriterija (detaljnije u poglavlju 4.4.2.).

Provedeno je i klasteriranje metodom k srednjih vrijednosti te su određeni klasteri ispitanika na temelju grupiranja podataka iz ankete prema sličnostima određenih parametara (detaljnije u poglavlju 4.4.3.).

Identificiranje alternativa također je rađeno na temelju znanstvenih i stručnih izvora, na način da je u prvom koraku napravljena inicijalna lista alternativa koja je sadržavala oblike e-učenja prema raznim klasifikacijama, a u drugom koraku je na temelju analize inicijalne liste napravljena revidirana lista alternativa (oblika učenja) koje su bile input u modele za višekriterijsko odlučivanje (detaljnije u poglavlju 5.2.1.).

Nakon što su definirane alternative i kriteriji, razvijeni su modeli za višekriterijsko odlučivanje: AHP (Analitički hijerarhijski proces) i ANP (Analitički mrežni proces) modeli u alatima TeamEC2000 (Expert Choice, 2000.) i SuperDecisions (SuperDecisions, 2006.) koji služe kao potpora u donošenju odluke o uvođenju e-učenja u visoko školstvo na višim razinama (sveučilišta i fakulteta) te nižim razinama (katedre i kolegija).

Ulaz (input) u hijerarhijsku strukturu AHP modela bili su tzv. „pročišćeni“ kriteriji koji su izdvojeni postupkom faktorske analize i alternative definirane pregledom znanstvene i stručne literature (detaljnije u poglavlju 5.2.1.).

Mrežna struktura ANP modela kompleksnija je i zahtjevnija jer uzima u obzir razne forme zavisnosti i povratne veze između kriterija i alternativa. Zavisnosti i povratne veze između kriterija i alternativa, postavljene su na temelju znanja prikupljenog pregledom literature, a evaluirane su od strane eksperta domene (detaljnije u poglavlju 6.2.1.).

3.2.3. Faza donošenja odluka

U fazi donošenja odluke, odlučivanjem pomoću razvijenih modela za višekriterijsko odlučivanje: AHP modela i ANP modela donesene su odluke o uvođenju e-učenja u visoko školstvo na nižim razinama (katedre i kolegija) te višim razinama (sveučilišta i fakulteta).

Na temelju definiranih kriterija i podkriterija te alternativa, u fazi razvijanja i izgradnje modela, razvijen je AHP model (engl. *Analytic Hierarchy Process*) za višekriterijsko odlučivanje o obliku uvođenja e-učenja na razini određene katedre i/ili kolegija. Problem izbora oblika e-učenja na razini katedre i kolegija je višekriterijski problem. Za rješavanje takvih problema postoji više metoda koje se temelje na različitim matematičkim teorijama, ali za ovaj konkretan problem je najpogodnija metoda Analitički hijerarhijski proces (AHP). AHP metoda spada u najpoznatije i posljednjih godina najviše korištene metode za odlučivanje kada se odluka (izbor neke od raspoloživih alternativa ili njihovo rangiranje) temelji na više kriterija koji imaju različitu važnost i/ili koji se izražavaju pomoću različitih skala.

Razvijeni AHP model je testiran na Fakultetu organizacije i informatike, na Katedri za kvantitativne metode, za kolegij Matematika te je provedeno grupno odlučivanje, integriranje različitih aspekata mišljenja te prezentiranje jedinstvenog zajedničkog rješenja donositelja odluke. U razvoju i testiranju modela koristio se alat TeamEC2000 (Expert Choice, 2000.). Provedeno je grupno odlučivanje u koje je bilo uključeno petero sudionika kompetentnih za rješavanje definiranog problema odlučivanja. Uspoređivanje u parovima koje je temelj AHP metode, omogućilo je sudionicima grupnog odlučivanja da procjene koji od oblika e-učenja, će s obzirom na definirane kriterije i podkriterije odlučivanja, donijeti veće prednosti u učenju i podučavanju (detaljnije u poglavlju 5.2.).

U fazi razvijanja i izgradnje modela, razvijen je i ANP model u kojeg su ugrađene složene interakcije između kriterija za odlučivanje. Metoda ANP (engl. *Analytic Network Process*) predstavlja generalizaciju analitičko-hijerarhijskih procesa, i to tako što se preko povratne veze hijerarhija zamjenjuje mrežom (Saaty, 2005.).

ANP metoda se koristi za donošenje strateških odluka na razini sveučilišta i fakulteta. Primjenom ove metode, koja uzima u obzir međusobnu interakciju kriterija, znatno se povećava stabilnost izabrane alternative te je zato primijenjena u donošenju odluka na višim strateškim razinama.

Testiranje ANP modela, točnije odlučivanje metodom analitičkog mrežnog procesa, izvršeno je od strane eksperta domene koji je ujedno član Povjerenstva za izradu strategije e-učenja Sveučilišta u Zagrebu i član Povjerenstva za izradu strategije e-učenja Fakulteta organizacije i informatike, te time kompetentan i sa odgovarajućim stupnjem odgovornosti za donošenje strateških odluka (detaljnije u poglavlju 6.2.).

Ekspert domene je svojim procjenama, uspoređivanjem u parovima, postavio prioritete alternativa i težine kriterija te su dobiveni rezultati poslužili kao input u Strategiju za e-učenje Fakulteta organizacije i informatike (detaljnije u poglavlju 7.2.).

3.2.4. Faza provođenja

U fazi provođenja odluke definiraju se akcijski plan i kontrolni sustav pomoću kojih se provodi i kontrolira provedba odluke o uvođenju e-učenja u institucije visokog školstva u Hrvatskoj.

Faza provođenja kao posljednja faza u procesu strateškog planiranja i donošenja odluke o uvođenju e-učenja, nije obuhvaćena u istraživanju koje je provedeno u okviru ove doktorske disertacije. Međutim, rezultati istraživanja su doprinijeli definiranju plana aktivnosti i kvantitativnih pokazatelja koji služe za praćenje ostvarivanja strategija. U povjerenstvu koje je izradilo Strategiju e-učenja Fakulteta organizacije i informatike, sudjelovala je i autorica doktorske disertacije.

Aktivnosti preko kojih će se provoditi donesene strategije, definirane su unutar sljedećih područja strateškog djelovanja (Strategija e-učenja UniZG, 2007.), (Strategija e-učenja FOI, 2007.):

- A) unapređenje formalno-pravnog i organizacijskog okruženja, osiguravanje održivosti,
- B) razvoj ljudskih potencijala,
- C) podrška nastavnicima,
- D) podrška studentima,
- E) razvoj obrazovnih sadržaja i
- F) razvoj temeljne i specifične infrastrukture.

U strategijama su definirani i kvantitativni pokazatelji preko kojih će se tijekom razdoblja od 2007. do 2010. godine pratiti ostvarivanje strategije Sveučilišta u Zagrebu (Strategija e-učenja UniZG, 2007.) i strategije Fakulteta organizacije i informatike u razdoblju od 2008. do 2010. godine (Strategija e-učenja FOI, 2007.). Neki od definiranih kvantitativnih pokazatelja su: Postotak kolegija koji aktivno koriste virtualno okruženje za učenje (VLE/LMS) za isporuku materijala i komunikaciju sudionika u obrazovnom procesu, Postotak nastavnika i suradnika koji aktivno koriste virtualno okruženje za učenje (VLE/LMS) i Web 2.0 tehnologije u procesu podučavanja, Postotak studenata na završnoj godini preddiplomskog studija koji su aktivno koristili virtualno okruženje za učenje (VLE/LMS) i Web 2.0 tehnologije u procesu učenja, Broj (na godišnjoj razini) materijala za e-učenje odobrenih od strane nadležnog

fakultetskog/sveučilišnog povjerenstva, Postotak nastavnika i suradnika uključenih u programe usavršavanja, Broj osoba (*FTE-full time equivalent*) angažiranih na potpori e-učenju i dr.

Detaljna kvalitativna analiza Strategije e-učenja na Sveučilištu u Zagrebu i Strategije e-učenja Fakulteta organizacije i informatike izvršena je u poglavljima 7.1. i 7.2.

4. ISTRAŽIVANJE

4.1. Ciljevi istraživanja

Cjelokupno istraživanje koje je provedeno u okviru doktorske disertacije integrira kvantitativne i kvalitativne metode istraživanja. U ovom poglavlju interpretirani su rezultati kvantitativnih metoda istraživanja: ankete, deskriptivne statistike, faktorske analize i klasteriranja metodom *k* srednjih vrijednosti te rezultati kvalitativne analize primjera strategija e-učenja vodećih europskih sveučilišta i fakulteta.

Navedene kvantitativne i kvalitativne metode služe za testiranje prve hipoteze:

H1: U procesu strateškog planiranja uvođenja e-učenja na visokoškolske institucije, moguće je identificirati i ocijeniti važnost ciljeva i prednosti e-učenja te važnost kriterija za odlučivanje kod uvođenja e-učenja.

Ciljevi istraživanja koji su postignuti primjenom navedenih metoda su:

- sistematizacija postojećih strategija e-učenja vodećih europskih sveučilišta i fakulteta,
- identifikacija prednosti i ciljeva e-učenja te kriterija za odlučivanje kod uvođenja e-učenja u visoko školstvo u Hrvatskoj na temelju primjera strategija e-učenja vodećih europskih sveučilišta i fakulteta i
- ocjenjivanje važnosti prednosti i ciljeva e-učenja te važnosti kriterija (podkriterija) odlučivanja kod uvođenja e-učenja.

U postupku kreiranja ankete je provedena kvalitativna analiza primjera strategija e-učenja vodećih europskih sveučilišta, s ciljem definiranja prednosti i ciljeva uvođenja e-učenja te razvoja teoretskog modela kriterija odlučivanja za uvođenje e-učenja na hrvatska sveučilišta i fakultete (detaljnije u poglavlju 4.3.1.).

Metodom ankete su prikupljeni podaci od ispitanika eksperata za e-učenje u visokom školstvu, te su prikupljeni podaci obrađeni metodama deskriptivne statistike. Dobiveni rezultati su omogućili identifikaciju i određivanje važnosti prednosti i ciljeva uvođenja e-učenja, te identifikaciju i ocjenu važnosti kriterija odlučivanja (detaljnije u poglavlju 4.4.1.).

Faktorska analiza je provedena na rezultatima ankete. Osnovni cilj primjene faktorske analize bio je validacija i racionalizacija postavljenog teoretskog modela kriterija odlučivanja za uvođenje e-učenja na hrvatska sveučilišta i fakultete te je njenom provedbom reduciran broj kriterija s 27 kriterija na 21 kriterij (detaljnije u poglavlju 4.4.2.), koji su služili kao input u AHP i ANP model (detaljnije u poglavlju 6. i 7.).

Klasteriranje metodom k srednjih vrijednosti primijenjeno je kako bi se ispitanici grupirali u klustere sličnih osobina koji najprikladnije obuhvaćaju određene skupine podataka prema njihovim karakteristikama. Prepoznate su i izdvojene ključne karakteristike za četiri klastera ispitanika (detaljnije u poglavlju 4.4.3.).

4.2. Metode istraživanja

Metoda u znanosti znači način istraživanja i izlaganja predmeta (stvari ili pojave) koji znanstvenik istražuje. Znanstvenom metodom naziva se i svaki način znanstvenog istraživanja koji osigurava sigurno, sređeno, sistematično, precizno i točno znanje (Žugaj, 2006.).

Odabir pristupa istraživanja te metoda istraživanja koje će koristiti istraživač, vrlo je važan kako bi se precizno definirali načini prikupljanja znanja i ciljevi istraživanja. Prema Creswellu, razlikuju se tri osnovna pristupa istraživanju: kvantitativni, kvalitativni i kombinirani (Creswell, 2003.). Koji će pristup odabrati glavni istraživač ovisi o više aspekata od kojih možemo izdvojiti (Creswell, 2003.): prirodu problema koja se istražuje, osobno iskustvo istraživača i auditorij kojem će se rezultati prezentirati.

Ukoliko imamo novu temu, novi problem ili su nepoznate varijable koje utječu na pojavu nekog problema, najbolji pristup je kvalitativan pristup. Korištenje kvalitativnog pristupa se preporučuje i za provjeru teorije u praksi. Kombinirana metoda se koristi kada se žele generalizirati rezultati istraživanja na populaciju i dati detaljan pogled na značenje fenomena ili koncepta za pojedince (Creswell, 2003.).

Vezano uz osobno iskustvo istraživača, može se reći da su osobe koje imaju tehničko obrazovanje, sklonije znanstvenom stilu pisanja, primjeni računalnih statističkih programa i

odabiru kvantitativnih metoda istraživanja. Osobe spretnije u pisanju tekstova, s iskustvom u intervjuiranju i radu s računalnim programima za analizu tekstova, bit će sklonije kvalitativnom istraživanju. Istraživač koji se odluči za kombiniranu metodu istraživanja treba vladati i kvantitativnim i kvalitativnim istraživanjima.

Način istraživanja ovisi i o auditoriju kojem će se prezentirati rezultati istraživanja (časopisi, konferencije, kolege u struci, i sl.) i o njihovom iskustvu u kvantitativnom, kvalitativnom ili mješovitom istraživanju.

Pristup koji se koristi u ovoj doktorskoj disertaciji je kombinirani pristup koji integrira primjenu kvantitativnih i kvalitativnih metoda. U okviru kombinirane metode se koriste anketni upitnici zatvorenog tipa, prikupljaju se i analiziraju i tekstualni i numerički podaci, koriste statističke obrade prikupljenih podataka i metode za višekriterijsko odlučivanje. Odabrana metodologija istraživanja je paralelna transformativna strategija u kojoj se koriste i određena teoretska znanja kako bi se provelo istraživanje u kojem se istovremeno prikupljaju i kvalitativni i kvantitativni podaci.

4.2.1. Anketa

Metoda ankete je jedna od najčešćih metoda za prikupljanje podataka u društvenim istraživanjima. Prema Zeleniki, metoda anketiranja je postupak kojim se grupi ispitanika upućuje anketni upitnik, a na temelju njihovih pisanih odgovora se istražuju i prikupljaju podaci, informacije, stavovi i mišljenja o predmetu istraživanja (Zelenika, 1998.). U užem smislu, anketa je pisano prikupljanje podataka o stavovima i mišljenjima na reprezentativnom uzorku ispitanika uz pomoć upitnika (Žugaj, 2006.).

Pouzdanost metode anketiranja leži u pravilnom odabiru reprezentativnog uzorka nad kojim se provodi anketiranje, ali i o jasno postavljenoj svrsi i ciljevima zbog kojih se provodi upravo ova metoda. Istraživač koji provodi anketu treba dobro poznavati problem ili znanstveno pitanje koje istražuje.

Anketni upitnik sastoji se od nekoliko osnovnih elemenata: uvoda u anketu, upitnika (pitanja) i uputstva ispitanicima. Prije nego što istraživač počne kreirati anketu, treba dobro poznavati relevantnu literaturu o problemu, kao i metode istraživanja koje su korištene u ranijim istraživanjima, kako bi bio siguran u dobro poznavanje problema kojeg ispituje i plan vlastitog istraživanja.

Postoje dvije osnovne skupine pitanja po obliku: otvorena i zatvorena pitanja (Žugaj, 2006.). Kod otvorenih pitanja, ispitaniku se ne postavljaju nikakvi okviri za odgovor, ostavlja mu se prazan prostor u koji on prirodno i spontano, bez usmjeravanja, upisuje svoj odgovor. Zatvorena pitanja ograničavaju ispitanika u mogućnostima odgovora jer se nakon postavljenog pitanja nude i mogući odgovori. Osim što mogu imati velik broj ponuđenih odgovora, pitanja mogu biti i s ponuđenim odgovorima intenziteta (optimalno je 5 intenziteta). Zatvorena pitanja omogućuju generalizaciju, pa se pomoću njih provjeravaju postavljene hipoteze (Žugaj, 2006.).

Anketiranje se može provesti na više načina: osobno, putem pošte ili elektroničkom poštom, a s obzirom na istovremeni obuhvat: individualno ili grupno.

4.2.2. Deskriptivna statistika

Deskriptivna statistika opisuje, uspoređuje i analizira masovne pojave temeljem prikaza i brojčane obrade poznatih podataka (Tepeš, 2004.). Pri tome je masovna pojava statistički skup istovrsnih elemenata, odnosno onih elemenata koji imaju isto obilježje. Statistički skup je definiran pojmovno, prostorno i vremenski.

Statistička obilježja su opća svojstva elemenata statističkog skupa po kojima su elementi istovrsni i po kojima se razlikuju. Opisna obilježja se izražavaju riječima, redosljedna obilježja se izražavaju rangom, numerička se izražavaju brojem, a vremenska trenutkom (Tepeš, 2004.).

Najčešće nije moguće izmjeriti sve vrijednosti promatranog statističkog obilježja, pa se iz populacije odabire reprezentativni uzorak. Stoga razlikujemo skupove podataka dobivene mjerenjem (opažanjem) odabranog statističkog obilježja na populaciji – populacijske podatke, od onih dobivenih na uzorku iz populacije – uzorački podaci. Cilj statističke analize skupova populacijskih podataka je izdvojiti njihove značajke, pri čemu se koriste metode deskriptivne statistike. Cilj statističke analize skupova uzoračkih podataka je na osnovi podataka iz uzoraka donijeti određene zaključke o populacijskoj razdiobi promatranog statističkog obilježja, pri čemu se koriste i metode deskriptivne statistike i metode inferencijalne statistike (Huzak, 2003.).

Razlikujemo i dvije osnovne vrste varijabli: numeričke i kategorijalne. Numeričke varijable dijele se na diskretne i kontinuirane (neprekidne). Kategorijalne varijable mogu biti: dihotomne – imaju samo dva razreda (npr. odgovori da/ne), nominalne – razredi su neuređeni, te ordinalne – vrijednosti su im uređene (Huzak, 2003.).

Za mjerenje centralnih tendencija skupova podataka, koriste se aritmetička sredina, medijan i mod (Huzak, 2003.). Mjere centralnih tendencija skupova podataka su prikazane u tablici 4-1.

Tablica 4-1. Mjere centralnih tendencija skupova podataka (Huzak, 2003.)

Mjere centralnih tendencija skupova podataka	Objašnjenje
Aritmetička sredina	<p>Neka je X numerička varijabla, a x_1, x_2, \dots, x_n njenih n vrijednosti, tj. niz brojeva. Aritmetička sredina brojeva je tada:</p> $\bar{x} = \frac{1}{n}(x_1 + x_2 + \dots + x_n) = \frac{1}{n} \sum_{i=1}^n x_i .$
Medijan	<p>Neka je X numerička ili ordinalna varijabla, a x_1, x_2, \dots, x_n njenih n vrijednosti. Tada je njene vrijednosti moguće urediti: $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$. Medijan skupa podataka je vrijednost od X za koju vrijedi da je 50% svih podataka u skupu manje ili jednako toj vrijednosti i 50% svih podataka joj je veće ili jednako.</p> <p>Za neparan broj podataka n, $n = 2k-1$, medijan $m = x_{(k)}$. Medijan skupa s parnim brojem podataka n, $n = 2k$, medijan</p> $m = \frac{x_{(k)} + x_{(k+1)}}{2} .$
Mod	<p>Mod je vrijednost obilježja X koja se u skupu podataka pojavljuju najviše puta, ima najveću frekvenciju. To je najtipičnija vrijednost promatrane varijable.</p>

Važno svojstvo distribucije podataka je i njihova raspršenost. Objašnjenja mjera raspršenja podataka navedena su u tablici 4-2. (Huzak, 2003.).

Tablica 4-2. Mjere raspršenja podataka (Huzak, 2003.)

Mjere raspršenja podataka	Objašnjenje
Standardna devijacija	<p>Standardna devijacija je srednje kvadratno odstupanje podataka od njihove aritmetičke sredine:</p> $s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} .$
Varijanca	<p>Broj s^2 zovemo varijanca skupa podataka:</p> $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 .$
Koeficijent varijacije	<p>Koeficijent varijacije je relativna mjera disperzije, a služi za mjerenje i uspoređivanje disperzije u različitim distribucijama. Pomoću standardne devijacije ne može se uspoređivati intenzitet disperzije u različitim distribucijama, naročito ako su jedinice mjere različite.</p> <p>Koeficijent varijacije je omjer između standardne devijacije i aritmetičke sredine. Taj omjer se može pomnožiti sa 100, i onda predstavlja postotak standardne devijacije od aritmetičke sredine. U određenim slučajevima može biti i veći od 100%.</p>
Raspon	<p>Raspon je razlika maksimalne i minimalne vrijednosti u uzorku: $R = \max_{1 \leq i \leq n} x_i - \min_{1 \leq i \leq n} x_i = x_{(n)} - x_{(1)} .$</p>

4.2.3. Faktorska analiza

Faktorska analiza kao skup statističko-matematičkih postupaka pogodnih za analizu podataka o međusobnoj povezanosti među promatranim pojavama, pokazala se korisnom u svim situacijama gdje se u istraživanjima istovremeno pojavljuje veći broj varijabli koje stoje u međusobnim korelacijama i gdje se zahtijeva utvrđivanje osnovnih izvora kovarijacije među podacima (Fulgosi, 1988.). Kod korelativne povezanosti pojava, promjene u jednoj i u drugoj pojavi mogu se javljati paralelno, a da jedne nisu uzrok drugima, za razliku od uzročno-posljedične povezanosti u kojoj je jedna pojava ili događaj uzrok nastajanja ili javljanja neke druge pojave, događaja ili promjene.

Faktorska analiza nam omogućava izračunavanje koeficijenta korelacije ili koeficijenta asocijacije između varijabli. Varijablama smatramo podatke dobivene mjerenjem promjena na pojavama koje se promatraju i proučavaju. Ukoliko su promatrane pojave međusobno povezane, onda možemo utvrditi veličinu korelacije svake promatrane pojave sa svakom drugom promatranom pojavom. To znači da ćemo kao rezultat takva proučavanja dobiti simetričnu matricu s brojnim koeficijentima korelacije. Broj takvih koeficijenata korelacije je $n(n-1)/2$ gdje je n broj varijabli. Koeficijenti korelacije nam pokazuju da su proučavane pojave u vezi te da su veze između nekih slabije odnosno jače.

Faktorska analiza omogućava i dublje prodiranje u međusobne zavisnosti i odnose između pojava te preko skupa matematičko-statističkih postupaka omogućuje da se u većem broju varijabli, među kojima postoji povezanost, utvrdi manji broj temeljnih varijabli koje objašnjavaju takvu međusobnu povezanost. Te temeljne varijable se zovu faktori. Varijable koje se promatraju u faktorskoj analizi se zovu manifestne varijable, a faktori koji se utvrđuju na temelju međusobnih odnosa manifestnih varijabli se zovu latentne varijable.

Prema tome, osnovni cilj faktorske analize je da umjesto velikog broja međusobno povezanih i zavisnih manifestnih varijabli koje su rezultirale iz nekog istraživanja utvrdimo manji broj međusobno nezavisnih latentnih varijabli koje mogu objasniti međusobne odnose manifestnih varijabli (Fulgosi, 1988.).

Postoje dvije osnovne strategije korištenja faktorske analize (Fulgosi, 1988.): eksploratorna i konfirmatorna faktorska analiza. Eksploratorna faktorska analiza utvrđuje temeljne faktore ili izvore varijacija i kovarijacija među promatranim varijablama, a konfirmatornom faktorskom analizom se provodi objektivan test određenoga strukturalnog modela ili teorije. Istraživač polazi od unaprijed formuliranog modela, hipoteze ili teorije o strukturi temeljnih izvora varijacije i kovarijacije među promatranim varijablama i testira taj model, hipotezu ili teoriju. Za potrebe ovog istraživanja je korištena metoda konfirmatorne faktorske analize.

4.2.4. Klasteriranje metodom k srednjih vrijednosti

Klasteriranje se može definirati kao grupiranje ili objedinjavanje objekata sličnih karakteristika (Panian, 2003.). Ono spada u jednu od poznatijih metoda rudarenja podataka. Za kvalitetno klasteriranje moramo raspolagati dovoljnom količinom podataka o nekom objektu kako bi se objekt sa svojom specifičnom karakteristikom mogao jednoznačno svrstati u određenu grupu, odnosno klaster. Klasteriranje segmentira određenu grupu podataka na niz manjih grupa ili klastera sličnih osobina. Podaci se grupiraju zajedno na temelju sličnosti određenih parametara.

Alati za klasteriranje moraju na zahtjev korisnika pronaći klastere koji će najprikladnije obuhvatiti određene skupine podataka prema njihovim karakteristikama, npr. kupce s nekim zajedničkim obrascem ponašanja prilikom kupnje ili ispitanike sa sličnim mišljenjem o zadanom problemu. Oni određuju tzv. centroid koji odražava ključne karakteristike svakog klastera.

Posebni aspekti metoda klasteriranja vezani su uz pitanja koja želimo riješiti procesom obrade podataka, odnosno proces pripreme podataka za njihovu efikasnu primjenu kao što su:

- pitanje mjerenja udaljenosti primjera (metrika prostora),
- izbor ispravnog broja grupa,
- interpretacija grupa.

Sličnost između članova populacije nad kojom se obavlja analiza računa se primjenom funkcija udaljenosti, najčešće euklidskom ili Manhattan udaljenosti u višedimenzionalnom prostoru.

Postoji čitav niz metoda klasteriranja, međutim najpoznatiji, a ujedno i jedan od jednostavnijih algoritama za klasteriranje je tzv. algoritam "*k* srednjih vrijednosti" (*k-means* klasteriranje) (Panian, 2003.). Algoritam "*k* srednjih vrijednosti" dijeli skupinu podataka ili tzv. osnovnu populaciju na određeni broj manjih segmenata ili klastera. Broj klastera se označava sa *k*, pri čemu svaki od klastera sadrži *n* sličnih elemenata. Sličnost elemenata, a prema tome i njihovo smještanje u pojedini klaster, algoritam procjenjuje na temelju funkcije udaljenosti.

Ova metoda se može algoritamski prikazati na sljedeći način (Panian, 2003.):

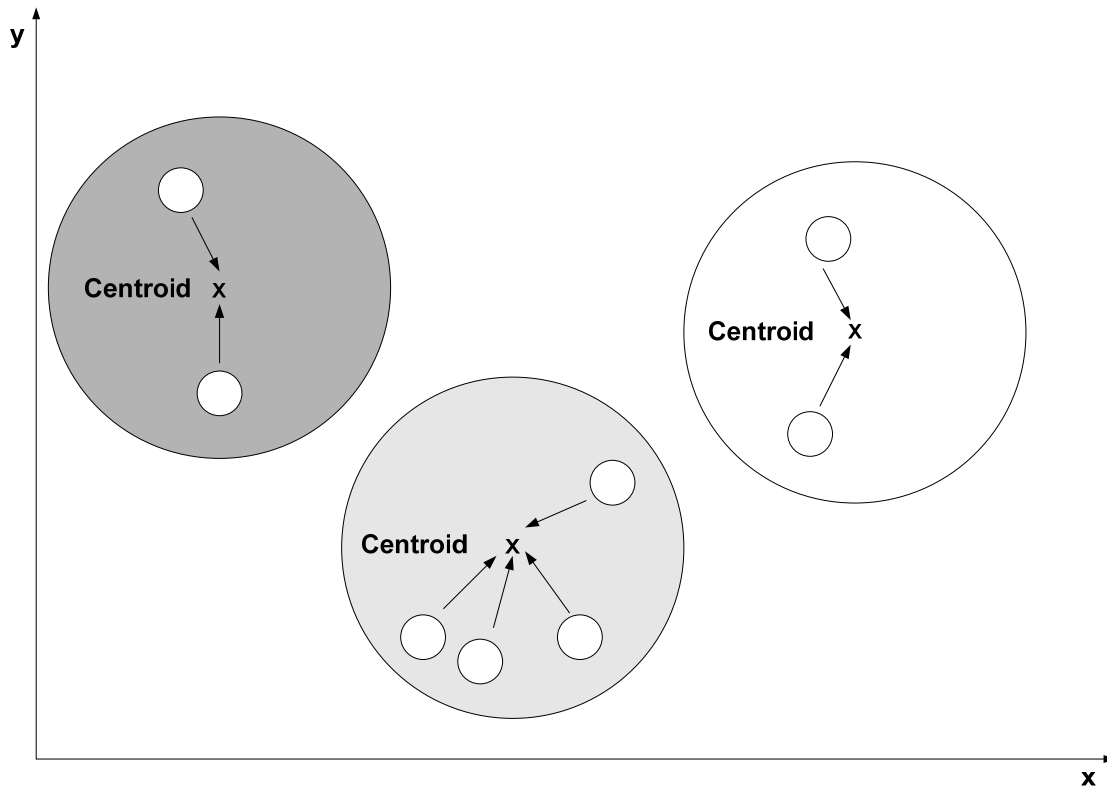
1. Izaberi proizvoljno *k* segmenata (klastera)
2. Odredi središte („centroid“) za svaki od *k* segmenata
3. Ponavljaj:
 - Pridruži pomoću funkcije udaljenosti sve elemente populacije njihovim najbližim klasterima (proračun se vrši na temelju centralnih vrijednosti - „centroida“)
 - Proračunaj novu vrijednost središta klastera (centroida) za svaki klaster pojedinačno kao prosječnu vrijednost udaljenosti objekata od središta
 - Ponavljaj sve dok se mijenjaju vrijednosti središta klastera (vrijednosti centroida).

Algoritam *k*-srednjih vrijednosti je iterativna procedura u kojoj je na početku potrebno kao ulaznu vrijednost definirati broj - *k* segmenata/klastera. Srednja vrijednost u algoritmu ili središte klastera (centroid) odnosi se na prosječnu lokaciju određene grupe objekata u višedimenzionalnom prostoru definiranom objektima kao osima tog prostora. Koordinate centroida izračunavaju se kao prosječne vrijednosti koordinata svih objekata koji pripadaju toj grupi. Iterativna procedura redefiniranja centroida te raspoređivanja primjera u odgovarajuće grupe zahtijeva obično samo nekoliko iteracija do zadovoljavajuće konvergencije. Elementi u iterativnim procesima teže vezivanju uz centralne vrijednosti klastera, klasteriranje svakom slogu dodjeljuje vrijednost pripadnosti klastera, te opcionalno pridružuje vrijednosti udaljenosti od centra klastera.

Vrijednost svakog objekta predstavlja udaljenost tog objekta od ishodišta višedimenzionalnog prostora ili središta klastera (centroida) po koordinati objekta. Vrijednosti objekta moraju biti numeričke ili moraju biti transformirane u numeričke vrijednosti, a zatim i normalizirane da bi se omogućilo ravnopravno izračunavanje po svim koordinatama prostora.

Postoji čitav niz metoda za pridjeljivanje inicijalne vrijednosti klastera (Panian, 2003.). U originalnoj varijanti algoritma, čiji je autor J. B. MacQueen (1967.g.), za inicijalne vrijednosti klastera uzima se prvih k vrijednosti iz populacije, gdje k predstavlja željeni broj klastera. Jedna od korištenih metoda svodi se i na slučajni odabir k elemenata iz populacije koje ujedno postaju centralne vrijednosti. Postoje i verzije algoritama koje bi trebale optimizirati proces klasteriranja. U tu skupinu pripada postupak koji sortira osnovnu populaciju, te se kao inicijalne vrijednosti klastera izabiru vrijednosti iz populacije koje se nalaze na prijelomnim točkama s obzirom na broj izabranih klastera. Prijelomna točka se u tom slučaju definira kao granična točka koja dijeli sortirani niz na jednaki broj elemenata s obzirom na izabrani broj klastera. Postoji i modifikacija opisane metode na način da se prijelomne točke generiraju na temelju minimalne i maksimalne vrijednosti sortiranog niza. U tom slučaju centralne vrijednosti ne moraju nužno biti elementi sortiranog niza nego proračunate vrijednosti.

Glavni nedostatak ove metode proizlazi iz potrebe za odabirom broja klastera od strane analitičara što u praksi znači da će se morati provesti nekoliko iterativnih procesa klasteriranja kako bi se formirao zadovoljavajući broj klastera. Drugi nedostatak je da pojedini programski paketi zanemaruju važnost normiranja ulaznih vrijednosti koje ulaze u proces klasteriranja, pa je potrebno prije analize normirati vrijednosti, kako bi svi atributi imali jednaki ponder važnosti. Grafički prikaz metode vidljiv je na slici 4-1.



Slika 4-1. Metoda "k srednjih vrijednosti"

4.3. Prikupljanje podataka za istraživanje

Prikupljanje podataka provedeno je kvantitativnom metodom anketiranja eksperata za e-učenje u visokom školstvu. Ispitanici su anketirani sa svrhom ocjenjivanja važnosti prednosti i ciljeva e-učenja te važnosti kriterija (podkriterija) odlučivanja kod uvođenja e-učenja.

Postupak kreiranja ankete koji je obuhvatio kvalitativnu analizu strateških dokumenata o uvođenju e-učenja i strategija e-učenja vodećih europskih sveučilišta, opisan je u poglavlju 4.3.1. Rezultati analize sociodemografskih karakteristika ispitanika u istraživanju interpretirani su u poglavlju 4.3.2. Postupak prikupljanja podataka je opisan u poglavlju 4.3.3.

4.3.1. Kreiranje ankete

Kreiranje ankete te provedba anketiranja s ciljem sistematizacije znanja od strane stručnjaka u području e-učenja u visokom školstvu, spada u drugu fazu procesa strateškog planiranja i donošenja odluke o uvođenju e-učenja, fazu razvijanja i izgradnje modela.

U fazi razvijanja i izgradnje modela, na temelju rezultata kvalitativne analize znanstvenih i stručnih izvora, strateških dokumenata te primjera strategija e-učenja vodećih europskih sveučilišta, definirani su ciljevi i prednosti e-učenja te je razvijen teoretski model (kriteriji i podkriteriji) za strateško planiranje i donošenja odluke o uvođenju e-učenja.

Glavni postupci u metodi kvalitativne analize su komparacija i razlikovanje različitih svojstava istih predmeta ili pojava, odnosno istih svojstava različitih pojava, a glavni su joj rezultati deskripcija, klasifikacija i definicija tih objekata analize (Žugaj, 2006.).

Definiranje i klasifikacija ciljeva i prednosti e-učenja i kriterija i podkriterija za donošenje odluke o uvođenju e-učenja, rezultati su kvalitativne analize sljedećih strategija e-učenja vodećih europskih Sveučilišta:

- Cambridge strategy of learning (Cambridge strategy of learning, 2006.)
- Oxford Brookes' e-learning strategy 2002 – 2005 (Oxford Brookes' e-learning strategy, 2006.)
- E-Learning Strategy - Cardiff University (E-Learning Strategy - Cardiff University, 2006.)
- E-learning Strategy - Edinburgh University 2004-7 (E-learning Strategy - Edinburgh University, 2006.)
- E-Learning Strategy - Imperial College, London (E-Learning Strategy - Imperial College, 2006.)
- E-learning Strategy Discussion Document - Massey University (E-learning Strategy Discussion Document - Massey University, 2006.)
- E-Learning Strategy - Queen's University Belfast (E-Learning Strategy - Queen's University Belfast, 2006.)

- E-Learning Strategy Consultation - Sussex University (E-Learning Strategy Consultation - Sussex University, 2006.)
- E-learning strategy – Warwick University (E-learning strategy – Warwick University, 2006.)
- E-Learning Strategy - University College Worcester (E-Learning Strategy - University College Worcester, 2006.)
- E-Learning Strategy - University of Ulster (E-Learning Strategy - University of Ulster, 2006.)
- E-Learning Strategy - University of Hull (E-Learning Strategy - University of Hull, 2006.)
- E-Learning Strategy - University of Dundee (E-Learning Strategy - University of Dundee, 2006.)
- E-Learning Strategy - University of Reading (E-Learning Strategy - University of Reading, 2006.)
- Teaching and Learning strategy – University of Durham (Teaching and Learning strategy – University of Durham, 2006.)

Provedena je i kvalitativna analiza mnogih znanstvenih i stručnih izvora te važnih europskih strateških dokumenata od kojih izdvajamo:

- Coimbra group (2002), European Union Policies and Strategic Change for eLearning in Universities, Report of the project “Higher Education Consultation in Technologies of Information and Communication”(HECTIC report) (Coimbra group, 2002.)
- Commission of the European Communities CEC: eLearning Action Plan, Communication from the commission to the council and the european parliament, Brussels, 28.3.2001, COM (2001)172 final, 2001. (CEC: eLearning Action Plan, 2001.)
- HEFCE strategy for e-learning, London, Higher Education Funding Council for England, London, 2005. (HEFCE strategy for e-learning, 2005.)
- OECD (Organisation for Economic Co-operation and Development), E-learning in Tertiary Education, Where do we stand?, Paris, 2005. (OECD, 2005.)
- Standards and Guidelines for Quality Assurance in the European Higher Education Area, European Association for Quality Assurance in Higher Education, Helsinki, Finland 2005.

(Standards and Guidelines for Quality Assurance in the European Higher Education Area, 2005.)

Identificirani ciljevi i prednosti e-učenja te kriteriji i podkriteriji za donošenje odluke o uvođenju e-učenja, prikazani su u tablicama 4-3.-4-5.

Tablica 4-3. Identificirane prednosti uvođenja e-učenja

Prednosti uvođenja e-učenja
1. Omogućava kolaborativno učenje (<i>collaborative learning</i>) (dinamičku interakciju s profesorima i studentima)
2. On-line pristup nastavnim materijalima (informacije su lakše dostupne)
3. Omogućava cjeloživotno obrazovanje (<i>lifelong learning</i>)
4. Neovisnost o vremenu i prostoru – fleksibilnost učenja
5. Objedinjavanje različitih medija za prijenos i prikaz informacija
6. Mogućnost prilagođavanja osobnom stilu učenja studenta (student uči samostalno si organizirajući vrijeme)
7. Omogućava da se vrijeme koje profesor i student imaju na raspolaganju iskoristi za najkvalitetnije obrazovne sadržaje, raspravu i prijenos znanja

Tablica 4-4. Identificirani ciljevi uvođenja e-učenja

Ciljevi uvođenja e-učenja
1. Inovirati i modernizirati sustav sveučilišnog obrazovanja
2. Prilagoditi se europskim iskustvima i trendovima
3. Omogućiti bolji i širi pristup obrazovanju potencijalnim studentima
4. Osposobiti studente - buduće građane društva znanja za cjeloživotno učenje
5. Unaprijediti kvalitetu obrazovnog procesa i ishoda učenja
6. Osigurati izlazak na međunarodno tržište obrazovanja – internacionalizacija
7. Osuvremeniti infrastrukturu i povećati primjenu informacijskih tehnologija u okviru sveučilišta/fakulteta

Tablica 4-5. Identificirani kriteriji i podkriteriji za donošenje odluke o uvođenju e-učenja

KRITERIJI I PODKRITERIJI
ORGANIZACIJSKA SPREMNOST OKRUŽENJA
Sveučilišni razvojni okvir - razvojna strategija obrazovanja na sveučilištu
Razvojna strategija fakulteta - podrška fakulteta razvojnim smjernicama
Organizacijska spremnost sveučilišta/fakulteta za promjene i uvođenje e-učenja
Financijska spremnost sveučilišta/fakulteta za uvođenje e-učenja
FORMALNO-PРАВNA SPREMNOST OKRUŽENJA
Sustav za zaštitu intelektualnog vlasništva na državnoj i akademskoj razini
Sustav i kriteriji napredovanja sveučilišnih nastavnika
Sustav vrednovanja i kontrole kvalitete na sveučilištu/fakultetu
Standardizacija digitalnih obrazovnih materijala
Mrežna infrastruktura (<i>on campus, off campus</i>)
Računalna opremljenost nastavnika i studenata
Tehnička opremljenost predavaonica i učionica na sveučilištu/fakultetu
Integralni informacijski sustav sveučilišta/fakulteta
RASPOLOŽIVOST SPECIFIČNE INFRASTRUKTURE I ALATA ZA E-UČENJE
Integralni sustav upravljanja procesom obrazovanja - <i>Managed learning environments</i>
Virtualno edukacijsko okružje - <i>Virtual Learning Environment (CMS, LMS, LCMS...)</i>
Repozitorij digitalnog obrazovnog materijala
Sustav ispitivanja uz pomoć računala
Mrežni videokonferencijski sustavi
Video i audio streaming
Proizvodnja video i audio materijala
Sustavi za simulacije i virtualnu stvarnost
RASPOLOŽIVOST LJUDSKIH RESURSA
Specijalizirani centar potpore e-učenju
Raspoloživost pomoćnog osoblja za tehničku potporu e-učenju
Raspoloživost pomoćnog osoblja za metodičku potporu e-učenju
Raspoloživost pomoćnog osoblja za grafičko oblikovanje, animaciju i video
RAZVOJ LJUDSKIH RESURSA
Sustav kontinuiranog usavršavanja nastavnog osoblja
Sustav kontinuiranog usavršavanja pomoćnog osoblja
Sustav izobrazbe studenata za upotrebu e-učenja

Teoretski model razvijen na temelju rezultata kvalitativne analize, koristio je kao podloga za anketu koja je bila strukturirana tako da izvrši prikupljanje i prioritizaciju podataka potrebnih za izradu strateških dokumenata: ciljeva uvođenja e-učenja, prednosti uvođenja e-učenja i kriterija važnih za strateško planiranje i odlučivanje o uvođenju e-učenja.

Anketa je sadržavala uvod, pitanja i uputstva te napomenu koja je jamčila da će se prikupljeni podaci upotrebljavati isključivo kao dio statističkog uzorka te da su traženi osobni podaci potrebni isključivo kao podloga za socijalnu profilaciju statističkog uzorka i da se neće koristiti u druge svrhe (sukladno Zakonu o zaštiti osobnih podataka NN 103/2003). Ispitanik je uz anketu dobio prilog s objašnjenjima kriterija i podkriterija, kako bi se izbjegla nesigurnost ili moguće nerazumijevanje pojedinih pojmova (kriterija/podkriterija) (Prilog 2).

Pitanja u anketi bila su većinom zatvorenog tipa osim pitanja koja su se odnosila na sociodemografske karakteristike ispitanika i posljednjeg pitanja čiji cilj je bio prikupljanje mišljenja i prijedloga ispitanika vezano uz ciljeve, prednosti, kriterije i podkriterije važne za uvođenje e-učenja u visoko školstvo u Hrvatskoj.

Od ispitanika je traženo da vrednuju ocjenama od 1-5 prednosti i ciljeve uvođenja e-učenja, te da odrede važnost pojedinog kriterija za odlučivanje o uvođenju e-učenja na sveučilišta/fakultete u Hrvatskoj. Ispitanici su imali i mogućnost upisa ciljeva, prednosti i kriterija ukoliko po njihovom mišljenju svi potrebni ciljevi, prednosti i kriteriji nisu pokriveni anketom.

Anketni upitnik (Prilog 3) bio je sastavljen od četiri osnovne cjeline:

1. dio: Opći sociodemografski podaci

Početni dio anketnog upitnika sastojao se od 5 pitanja otvorenog tipa i 4 pitanja zatvorenog tipa, u kojima su od ispitanika traženi osnovni podaci kao što su: ime i prezime, spol, starost, e-mail adresa, naziv institucije u kojoj ispitanik radi, radno mjesto, školska sprema, znanstveno – nastavno zvanje te znanstveno područje u kojem ispitanik djeluje.

2. dio: Ocjena važnosti za prednosti koje donosi uvođenje e-učenja u okviru sveučilišta/fakulteta

U ovoj grupi pitanja, ispitanici su zaokruživanjem ocjena od 1-5 (1-najmanja važnost, 5-najveća važnost) ocjenjivali prednosti uvođenja e-učenja na sveučilišta/fakultete. U anketi je bilo navedeno 7 prednosti koje su se ocjenjivale, te je ostavljena mogućnost upisa dodatnih prednosti po mišljenju ispitanika.

3. dio: Ocjena važnosti za ciljeve koji se žele postići uvođenjem e-učenja u okviru sveučilišta/fakulteta

U trećem dijelu ankete, ispitanici su zaokruživanjem ocjena od 1-5 (1-najmanja važnost, 5-najveća važnost) ocjenjivali ciljeve uvođenja e-učenja na sveučilišta/fakultete. U anketi je bilo navedeno 7 ciljeva koje su ocjenjivali ispitanici, te je ostavljena mogućnost upisa ciljeva po želji ispitanika.

4. dio: Ocjena važnosti kriterija (podkriterija) odlučivanja tijekom strateškog planiranja uvođenja e-učenja na hrvatska sveučilišta i fakultete

U četvrtom dijelu ankete, ispitanici su upisom ocjena od 1-5 (1-najmanja važnost, 5-najveća važnost) ocjenjivali kriterije (podkriterije) za odlučivanje o uvođenju e-učenja na hrvatska sveučilišta i fakultete. Ispitanici su ukupno trebali ocijeniti 27 podkriterija, koji su bili grupirani u 6 grupa (kriterija). Za svaki od kriterija (podkriterija) ispitanici su u prilogu mogli potražiti dodatno objašnjenje kako bi se izbjeglo nerazumijevanje pojmova. Ujedno je bio omogućen unos dodatnih kriterija (podkriterija) po mišljenju ispitanika. Zadnje pitanje u anketi je bilo pitanje otvorenog tipa, na koje su ispitanici odgovarali upisom svojih prijedloga i komentara.



4.3.2. Ispitanici u istraživanju

Pilot istraživanje je provedeno na prvoj radionici projekta EQIBELT pod nazivom „*Creating University E-Learning Vision and Strategy*” koja je održana u Dubrovniku od 3. do 5. ožujka 2006. godine. Istraživanje je provedeno uz sumentorstvo prof.dr.sc. Blaženke Divjak koja je članica EQIBELT projektnog tima te članica Povjerenstva za izradu strategije e-učenja Sveučilišta u Zagrebu. Kriteriji za odabir ispitanika bili su: ekspertiza u e-učenju i poznavanje učenja u okruženju visokog školstva. U anketiranju je sudjelovalo 33 ispitanika. Rezultati pilot istraživanja objavljeni su u znanstvenom radu «*Imaginative Acquisition of Knowledge - Strategic Planning of E-Learning*» u koautorstvu Blaženke Divjak i Nine Begičević i prezentirani na konferenciji *ITI 2006* (Divjak & Begicevic, 2006.). Cilj pilot istraživanja bilo je evaluirati upitnik putem intervjua prilikom provođenja ankete i odrediti stabilnost rezultata ankete na manjem uzorku prije nego se prijeđe na anketiranje većeg broja ispitanika.

Nakon radionice, u travnju i svibnju 2006., skup anketiranih hrvatskih stručnjaka za e-učenje u visokom školstvu povećan je na 90 ispitanika (N=90). Sudionici u istraživanju bili su: prorektori Sveučilišta u Zagrebu, dekani i prodekani fakulteta Sveučilišta u Zagrebu, Rijeci, Dubrovniku, članovi vladinih tijela odgovornih za uvođenje e-učenja, članovi EQIBELT projektnog tima, sveučilišni nastavnici koji izvode kolegije online, koordinatori CARNet referalnih centara, članovi CARNetovog tima za standardizaciju i valorizaciju digitalnih obrazovnih materijala, predstavnici e-learning akademije (ELA), eksperti za e-učenje u SRCU i CARNetu i drugi. Anketa nije bila anonimna, te se u prilogu 1 nalazi popis ispitanika.



Uzorak ispitanika je izabran po vlastitoj prosudbi stručnosti. Riječ je o tzv. «uzorku prema prosudbi stručnjaka», koji se preporuča ukoliko se anketa treba provesti u populaciji istomišljenika, odnosno među stručnjacima iz neke uske specijalnosti (Žugaj, 2006.).

Struktura ispitanika prikazana je grafički na slikama 4-2. – 4-8.





Slika 4-2. Struktura ispitanika prema spolu

U istraživanju je sudjelovalo više ispitanika muškog spola (N=48), međutim broj ispitanika muškog spola veći je za samo 6 %.




Slika 4-3. Struktura ispitanika prema starosnoj dobi

Struktura ispitanika prema starosnoj dobi pokazuje da je 85 % ispitanika mlađe od 50 godina. Od toga je 57 % ispitanika mlađe od 40 godina, što dodatno pokazuje da se radi o pretežito mladoj dobnoj skupini ispitanika.





Slika 4-4. Struktura ispitanika prema školskoj spremi

Na slici 4-4. može se vidjeti da 95 % ispitanika ima visoki stupanj obrazovanja. Najveći broj ispitanika (N=33) ima najviši stupanj obrazovanja doktorat znanosti. Postotak ispitanika s magisterijem znanosti iznosi 22 %, a s visokom školskom spremom 36 %.





Slika 4-5. Struktura ispitanika prema znanstveno-nastavnom zvanju

Od 90 ispitanika, 34% ih je u znanstveno-nastavnom zvanju, od toga 7 redovnih profesora, 12 izvanrednih profesora te 12 docenata. Veći broj ispitanika (N=59) nije u znanstveno-nastavnom zvanju.



Slika 4-6. Struktura ispitanika prema znanstvenom području djelovanja


Na slici 4-6. može se vidjeti da najveći broj ispitanika djeluje u području društvenih (N=36) i tehničkih znanosti (N=18). U području humanističkih znanosti djeluje 9 ispitanika, u području prirodnih znanosti 8 ispitanika, u području biomedicine i zdravlja 3 ispitanika i u području biotehničkih znanosti 1 ispitanik.



Slika 4-7. Struktura ispitanika prema instituciji/sektoru djelovanja

Više od polovice ispitanika (N=49) djeluje unutar Sveučilišta u Zagrebu, 10 ispitanika su predstavnici CARNeta i 7 ispitanika predstavnici SRCA. Sveučilište u Rijeci je u istraživanju

sudjelovalo s 4 ispitanika, Sveučilište u Osijeku s 3 ispitanika, a Sveučilište u Splitu samo s 1 ispitanikom. U istraživanju je sudjelovalo i 10 ispitanika koji djeluju unutar ICT sektora (s naglaskom na područje e-učenja) i 3 predstavnika MZOŠ-a i/ili Zavoda za školstvo RH.



Slika 4-8. Struktura ispitanika prema radnom mjestu/funkciji

Nastavno osoblje fakulteta čini najveći postotak ispitanika u istraživanju koji iznosi 45 %. 11% ispitanika su članovi Uprave određenog fakulteta, 4 % ispitanika su članovi Uprave jednog od sveučilišta, a 8 % ispitanika su vodeći predstavnici MZOŠ-a i/ili Zavoda za školstvo RH. 11 % ispitanika su voditelji projekata u CARNetu, a 8 % ispitanika su predstojnici sektora, voditelji projekata ili specijalisti u SRCU.

4.4. Rezultati obrade prikupljenih podataka

U obradi prikupljenih podataka primjenjena je metoda deskriptivne statistike, metoda faktorske analize i klasteriranje metodom *k* srednjih vrijednosti.

Primjenom deskriptivne statistike je napravljena analiza rezultata temeljem prikaza i brojčane obrade poznatih podataka. Rezultati statističke obrade prikazani su u poglavlju 4.4.1.

Osnovni cilj primjene metode faktorske analize bio je reduciranje broja podkriterija na temelju ocjena važnosti podkriterija prikupljenih od ispitanika koji su sudjelovali u anketiranju. Rezultati faktorske analize prikazani su u poglavlju 4.4.2.


Metoda klasteriranja je primjenjena u analizi ispitanika, kako bi segmentirala ispitanike u niz manjih grupa ili klastera sličnih osobina prema karakteristikama ispitanika. Rezultati klasteriranja metodom k srednjih vrijednosti prikazani su u poglavlju 4.4.3.

4.4.1. Rezultati statističke obrade

U obradi prikupljenih podataka primijenjena je metoda deskriptivne statistike kako bi se izrazile mjere centralnih tendencija skupova podataka i mjere raspršenja podataka i kako bi se grafički prikazale prosječne ocjene važnosti ciljeva i prednosti uvođenja e-učenja i prosječne ocjene važnosti podkriterija odlučivanja za uvođenje e-učenja na sveučilišta/fakultete.

U tablici 4-6. prikazani su osnovni statistički pokazatelji za varijable koje se odnose na ciljeve uvođenja e-učenja na sveučilišta/fakultete. Vrijednost moda za sve varijable je 4 ili 5 ($M_0=4$) ili ($M_0=5$)), što pokazuje da je najtipičnija vrijednost svih promatranih varijabli vrlo visoka ocjena 4 ili 5. Međutim raspon je po svim varijablama 3 ili 4 ($R=3$) ili ($R=4$) i minimalne vrijednosti su za sve varijable 1 ili 2 što pokazuje raznovrsnost ocjena od strane ispitanika. Statistički pokazatelji za svaku pojedinu varijablu ciljeva nalaze se u prilogu 4. Na slici 4-9. su prikazane prosječne ocjene važnosti ciljeva uvođenja e-učenja na sveučilišta/fakultete. Svi ciljevi koji su se ocjenjivali u anketi dobili su vrlo visoke ocjene važnosti što dokazuje da su već kvalitativnom analizom ciljevi selektivno definirani. Najvažniji cilj uvođenja e-učenja je *Unapređenje kvalitete obrazovnog procesa i ishoda učenja* s najvišom prosječnom ocjenom 4,49 ($\bar{x}=4,49$) što pokazuje da je svijest o važnosti kulture i politike kvalitete u visokoj naobrazbi velika, te da je e-učenje upravo jedan od načina postizanja željene razine kvalitete u visokom obrazovanju koja će zadovoljiti sve više zahtjeve tržišta i društva. Cilj *Inovacije i modernizacije sveučilišnog obrazovanja* ima također vrlo visoku ocjenu 4,47 ($\bar{x}=4,47$) što možemo interpretirati kao prepoznavanje potrebe za inovacijama i poboljšanjima u sustavu visokog obrazovanja. Nešto nižu ocjenu 3,79 ($\bar{x}=3,79$) ima cilj *Prilagodbe europskim iskustvima i trendovima*, što bi mogli

tumačiti kao pridavanje važnosti konkretnim rezultatima, poboljšanjima u visokom obrazovanju, a ne «slijepom» prilagođavanju europskim iskustvima bez kvalitetne pripreme i osiguranja stvarnih preduvjeta za promjene u visokom obrazovanju.




Slika 4-9. Prosječne ocjene važnosti ciljeva uvođenja e-učenja na sveučilišta/fakultete

Tablica 4-6. Statistički pokazatelji za varijable koje se odnose na ciljeve uvođenja e-učenja na sveučilišta/fakultete

		Inovirati sustav sveučilišnog obrazovanja	Prilagoditi se europskim iskustvima	Bolji i širi pristup obrazovanju	Osposobiti studente za cjeloživotno učenje	Unaprijediti kvalitetu obrazovnog procesa	Internacionalizacija obrazovanja	Osvremeniti infrastrukturu i povećati primjenu ICT
		1	2	3	4	5	6	7
N	<i>valjano</i>	90	90	90	90	90	90	90
	<i>nedostaje</i>	0	0	0	0	0	0	0
Aritmetička sredina		4,47	3,79	4,29	4,31	4,49	4,06	4,01
Medijan		5,00	4,00	4,50	5,00	5,00	4,00	4,00
Mod		5	4	5	5	5	4	5
Standardna devijacija		,86	,91	,84	,91	,72	,80	1,04
Varijanca		,75	,82	,70	,82	,52	,64	1,09
Koeficijent varijacije (%)		19,2393	24,0105	19,5804	21,1136	16,0356	19,7044	25,9351
Raspon		4	4	3	4	3	3	4
Minimalna vrijed.		1	1	2	1	2	2	1
Maksimalna vrijed.		5	5	5	5	5	5	5

U tablici 4-7. prikazani su osnovni statistički pokazatelji za varijable koje se odnose na prednosti uvođenja e-učenja na sveučilišta/fakultete. Iz tablice 4-7. vidljivo je da za ispitanike vrijedi da je najčešći stupanj slaganja s tvrdnjama u upitniku, odnosno najčešća ocjena koju su ispitanici davali po pojedinim varijablama, ocjena 5 ($M_o=5$) što vrijedi za varijable: *Online pristup nastavnim materijalima*, *Cjeloživotno obrazovanje*, *Fleksibilnost učenja* i *Bolje iskorištenje vremena*. Mod je 4 ($M_o=4$) za varijable: *Kolaborativno učenje*, *Objedinjavanje medija* i *Prilagođavanje stilu učenja studenta*. Za varijable: *Kolaborativno učenje*, *Objedinjavanje medija*, *Prilagođavanje stilu učenja studenta* i *Bolje iskorištenje vremena*, ispitivane tvrdnje odnose se za 50% ispitanika u stupnju od 5 do 4, a za 50% ispitanika taj se stupanj kreće od 4 do 1 ($M_e=4$). Za varijable: *Online pristup nastavnim materijalima*, *Cjeloživotno obrazovanje* i *Fleksibilnost učenja*, ispitivane tvrdnje su za 50% ispitanika u stupnju 5, a za 50% ispitanika taj se stupanj kreće od 5 do 1 ($M_e=5$). Statistički pokazatelji za svaku pojedinu varijablu ciljeva nalaze se u prilogu 4.

Na slici 4-10. su prikazane prosječne ocjene važnosti za prednosti uvođenja e-učenja na sveučilišta/fakultete. Sve prednosti koje su ocjenjivane u anketi imaju visoke prosječne ocjene, međutim najviše prosječne ocjene imaju prednosti: *Online pristup nastavnim materijalima* ($\bar{x}=4,68$), *Fleksibilnost učenja* ($\bar{x}=4,48$) i *Cjeloživotno obrazovanje* ($\bar{x}=4,28$). Dostupnost znanja koja se postiže online pristupom nastavnim materijalima ujedno daje mogućnost učenja studentima koji su dislocirani od sveučilišta, odnosno omogućava učenje neovisno o prostoru i vremenu. Prepoznata je i velika važnost cjeloživotnog učenja koje se može realizirati zahvaljujući e-učenju. Nešto nižu prosječnu ocjenu važnosti u odnosu na druge varijable ima prednost *Objedinjavanje medija za prijenos i prikaz informacija* ($\bar{x}=3,97$) koja je prepoznata kao važna, ali u odnosu na druge navedene prednosti kao nešto manje važna za uvođenje e-učenja.



Slika 4-10. Prosječne ocjene važnosti za prednosti uvođenja e-učenja na sveučilišta/fakultete

Tablica 4-7. Statistički pokazatelji za varijable koje se odnose na prednosti uvođenja e-učenja na sveučilišta/fakultete

		Kolaborativno učenje	Online pristup nastavnim materijalima	Cjeloživotno obrazovanje	Fleksibilnost učenja	Objedinjavanje medija	Prilagodavanje stilu učenja studenta	Bolje iskorištenje vremena
		1	2	3	4	5	6	7
N	<i>valjano</i>	90	90	90	90	90	90	90
	<i>nedostaje</i>	0	0	0	0	0	0	0
Aritmetička sredina		4,06	4,68	4,28	4,48	3,97	4,01	4,11
Medijan		4,00	5,00	5,00	5,00	4,00	4,00	4,00
Mod		4	5	5	5	4	4	5
Standardna devijacija		,84	,67	,92	,67	,88	,87	,99
Varijanca		,70	,45	,85	,45	,77	,75	,98
Koeficijent varijacije (%)		20,6896	14,3162	21,4953	14,9553	22,1662	21,6957	24,0875
Raspon		4	3	4	2	3	3	4
Minimalna vrijed.		1	2	1	3	2	2	1
Maksimalna vrijed.		5	5	5	5	5	5	5

U tablicama 4-8. – 4-13. prikazani su osnovni statistički pokazatelji za varijable koje se odnose na podkriterije za uvođenje e-učenja na sveučilišta/fakultete. Podkriteriji su grupirani u 6 kriterija: *Organizacijska spremnost okruženja*, *Formalno-pravna spremnost okruženja*, *Raspoloživost temeljne ICT infrastrukture*, *Raspoloživost specifične infrastrukture i alata za e-učenje*, *Raspoloživost ljudskih resursa* i *Razvoj ljudskih resursa*, te su statistički pokazatelji za podkriterije prezentirani u tablicama po pojedinom kriteriju. Dodatni statistički pokazatelji (frekvencija, postotak, kumulativni postotak) za svaki podkriterij nalaze se u prilogu 4.

Tablica 4-8. Statistički pokazatelji za varijable koje se odnose na **kriterij Organizacijska spremnost okruženja**

	Organizacijska spremnost okruženja				
		Sveučilišni razvojni okvir	Razvojna strategija fakulteta	Organizacijska spremnost sveučilišta i fakulteta	Financijska spremnost sveučilišta i fakulteta
		1	2	3	4
N	<i>valjano</i>	90	90	90	90
	<i>nedostaje</i>	0	0	0	0
Aritmetička sredina		4,34	4,54	4,42	4,21
Medijan		5,00	5,00	5,00	4,00
Mod		5	5	5	5
Standardna devijacija		,81	,66	,69	,92
Varijanca		,66	,43	,47	,84
Koeficijent varijacije (%)		18,6635	14,5374	15,6108	21,8527
Raspon		3	3	3	4
Minimalna vrijed.		2	2	2	1
Maksimalna vrijed.		5	5	5	5

Tablica 4-9. Statistički pokazatelji za varijable koje se odnose na **kriterij Formalno-pravna spremnost okruženja**

	Formalno-pravna spremnost okruženja				
		Sustav za zaštitu intelektualnog vlasništva	Sustav i kriteriji napredovanja nastavnika	Sustav vrednovanja i kontrole kvalitete	Standardizacija digitalnih obrazovnih materijala
		1	2	3	4
N	<i>valjano</i>	90	90	90	90
	<i>nedostaje</i>	0	0	0	0
Aritmetička sredina		3,49	4,04	4,20	4,03
Medijan		4,00	4,00	4,00	4,00
Mod		4	5	5	4
Standardna devijacija		1,05	,97	,85	,84
Varijanca		1,11	,94	,72	,71
Koeficijent varijacije (%)		30,0859	24,0099	20,2380	20,8436
Raspon		4	4	3	4
Minimalna vrijed.		1	1	2	1
Maksimalna vrijed.		5	5	5	5

Tablica 4-10. Statistički pokazatelji za varijable koje se odnose na **kriterij Raspoloživost temeljne ICT infrastrukture**

	Raspoloživost temeljne ICT infrastrukture				
		Mrežna infrastruktura	Računalna opremljenost nastavnika i studenata	Tehnička opremljenost predavaonica i učionica	Integralni informacijski sustav
		1	2	3	4
N	<i>valjano</i>	90	90	90	90
	<i>nedostaje</i>	0	0	0	0
Aritmetička sredina		4,50	4,43	4,17	3,86
Medijan		5,00	5,00	4,00	4,00
Mod		5	5	4	4
Standardna devijacija		,67	,72	,80	,88
Varijanca		,46	,52	,63	,78
Koeficijent varijacije (%)		14,8888	16,2528	19,1816	22,7979
Raspon		3	3	3	3
Minimalna vrijed.		2	2	2	2
Maksimalna vrijed.		5	5	5	5

Tablica 4-11. Statistički pokazatelji za varijable koje se odnose na **kriterij Raspoloživost specifične infrastrukture i alata za e-učenje**

		Raspoloživost specifične infrastrukture i alata za e-učenje							
		Integralni sustav upravljanja procesom obrazovanja	Virtualno edukacijsko okruženje	Repozitorij digitalnog obrazovnog materijala	Sustav ispitivanja uz pomoć računala	Mrežni videokonferencijski sustavi	Video i audio streaming	Proizvodnja audio i video materijala	Sustavi za simulacije i virtualnu stvarnost
		1	2	3	4	5	6	7	7
N	<i>valjano</i>	90	90	90	90	90	90	90	90
	<i>nedostaje</i>	0	0	0	0	0	0	0	0
Aritmetička sredina		4,06	4,31	3,97	3,57	3,60	3,49	3,61	3,32
Medijan		4,00	4,00	4,00	4,00	4,00	4,00	4,00	3,00
Mod		4	5	4	3	4	4	4	3
Standardna devijacija		,90	,80	,91	,99	,98	,94	,92	1,04
Varijanca		,82	,64	,82	,99	,96	,88	,85	1,07
Koeficijent varijacije (%)		22,1675	18,5615	22,9219	27,7311	27,2222	26,9341	25,4848	31,3253
Raspon		4	3	4	4	4	4	4	4
Minimalna vrijed.		1	2	1	1	1	1	1	1
Maksimalna vrijed.		5	5	5	5	5	5	5	5


Tablica 4-12. Statistički pokazatelji za varijable koje se odnose na **kriterij Raspoloživost ljudskih resursa**

	Raspoloživost ljudskih resursa				
		Specijalizirani centar potpore e-učenju	Raspoloživost pomoćnog osoblja za tehničku potporu	Raspoloživost pomoćnog osoblja za metodičku potporu	Raspoloživost pomoćnog osoblja za graf. oblikovanje, animaciju, video
		1	2	3	4
N	<i>valjano</i>	90	90	90	90
	<i>nedostaje</i>	0	0	0	0
Aritmetička sredina		4,56	4,36	4,08	4,09
Medijan		5,00	5,00	4,00	4,00
Mod		5	5	4	4
Standardna devijacija		,75	,85	,91	,82
Varijanca		,56	,73	,84	,67
Koeficijent varijacije (%)		16,4473	19,4954	22,3039	20,0488
Raspon		4	3	4	3
Minimalna vrijed.		1	2	1	2
Maksimalna vrijed.		5	5	5	5

Tablica 4-13. Statistički pokazatelji za varijable koje se odnose na **kriterij Razvoj ljudskih resursa**

	Razvoj ljudskih resursa			
		Sustav kontinuiranog usavršavanja nastavnog osoblja	Sustav kontinuiranog usavršavanja pomoćnog osoblja	Sustav izobrazbe studenata za upotrebu e-učenja
		1	2	3
N	<i>valjano</i>	90	90	90
	<i>nedostaje</i>	0	0	0
Aritmetička sredina		4,63	4,17	4,04
Medijan		5,00	4,00	4,00
Mod		5	4	4
Standardna devijacija		,66	,82	,87
Varijanca		,44	,68	,76
Koeficijent varijacije (%)		14,2548	19,6642	21,5346
Raspon		4	3	4
Minimalna vrijed.		1	2	1
Maksimalna vrijed.		5	5	5

Na slici 4-11. su prikazane prosječne ocjene važnosti kriterija odlučivanja za uvođenje e-učenja na sveučilišta/fakultete. Ispitanici su u anketi ocjenjivali podkriterije grupirane u 6 kriterija te su dobivene prosječne ocjene važnosti podkriterija (slika 4-12. i 4-13.) na temelju kojih su izračunate prosječne ocjene važnosti kriterija odlučivanja za uvođenje e-učenja. Kriteriji odlučivanja s najvišim prosječnim ocjenama su: *Organizacijska spremnost okruženja* ($\bar{x}=4,38$), *Razvoj ljudskih resursa* ($\bar{x}=4,28$) i *Raspoloživost ljudskih resursa* ($\bar{x}=4,27$). Najnižu ocjenu važnosti ima kriterij *Raspoloživost specifične infrastrukture* ($\bar{x}=3,74$).




Slika 4-11. Prosječne ocjene važnosti za kriterije odlučivanja za uvođenje e-učenja na sveučilišta/fakultete


Na slici 4-12. i slici 4-13. su prikazane prosječne ocjene važnosti podkriterija odlučivanja za uvođenje e-učenja na sveučilišta/fakultete. Svi podkriteriji su prepoznati kao važni za odlučivanje o uvođenju e-učenja i imaju visoke prosječne ocjene važnosti. Podkriteriji koji imaju prosječne ocjene važnosti veće od 4 prikazani su na slici 4-12., a oni koji imaju ocjenu manju od 4, na slici 4-13.

Tri najvažnija podkriterija su: *Sustav kontinuiranog usavršavanja nastavnog osoblja* ($\bar{x}=4,63$), *Specijalizirani centar potpore e-učenju na sveučilištu* ($\bar{x}=4,56$) i *Razvojna strategija fakulteta* ($\bar{x}=4,54$). Održavanje nastave uz pomoć tehnologije traži visok stupanj vještina nastavnog kadra, zahtijeva osposobljenost za izvođenje nastave i za tehnička pitanja. Takvo osposobljavanje treba biti sastavni dio kontinuiranog usavršavanja nastavnog osoblja. Ispitanici su naglasili važnost tog podkriterija iz razloga što nastavni kadar osjeća nedostatak tehničke i metodičke potpore. Specijalizirani centar potpore e-učenju drugi je podkriterij po važnosti što znači da su ispitanici prepoznali potrebu za takvim centrom. Centar potpore e-učenju treba osmisliti i uspostaviti kao trajno održiv centar koji služi kao multidisciplinarni sustav potpore sveučilišnim nastavnicima i studentima pri uvođenju i uporabi tehnologija e-učenja. Razvojna strategija fakulteta ocjenjena je trećim po važnosti podkriterijem odlučivanja za uvođenje e-učenja. Važno je da fakulteti izrade strateške odrednice u razvojnim planovima fakulteta za uvođenje e-učenja, osiguraju izvore financiranja za uvođenje e-učenja, uspostave infrastrukturu za implementaciju te motiviraju i omogućće adekvatno usavršavanje pomoćnog osoblja i nastavnika za korištenje sustava podrške e-učenju.

Tri najniže ocjenjena podkriterija su: *Zaštita intelektualnog vlasništva* ($\bar{x}=3,49$), *Video i audio streaming* ($\bar{x}=3,49$) i *Sustavi za simulacije i virtualnu stvarnost* ($\bar{x}=3,32$). Uspoređujući tri najviše ocjenjena podkriterija i tri najniže, mogu se vidjeti trenutni prioriteti u procesu uvođenja e-učenja u visoko obrazovanje u Hrvatskoj. Naime ispitanici su svjesni važnosti intelektualnog vlasništva, sustava za simulacije te video i audio streaminga, što se vidi po visokim prosječnim ocjenama, ali trenutačno stanje u Hrvatskoj je takvo da je prioritet postizanje organizacijske i strateške spremnosti za uvođenje e-učenja u visoko školstvo.



Slika 4-12. Prosječne ocjene važnosti za podkriterije odlučivanja za uvođenje e-učenja na sveučilišta/fakultete ($\bar{x} > 4$)



Slika 4-13. Prosječne ocjene važnosti za podkriterije odlučivanja za uvođenje e-učenja na sveučilišta/fakultete ($\bar{x} < 4$)

4.4.2. Rezultati faktorske analize

Osnovni cilj primjene faktorske analize bio je validacija i racionalizacija postavljenog teoretskog modela kriterija/podkriterija odlučivanja za uvođenje e-učenja na sveučilišta i fakultete.

Faktorska analiza je provedena statističkim programom SPSS (Brace, 2000.). U obradi rezultata uzeti su podaci za veličinu uzorka od 90 ispitanika, N=90. Nepotpunih upitnika nije bilo, pa nije bilo potrebe isključivanja pojedinih upitnika iz analize. Postupak faktorske analize proveden je metodom glavnih komponentata (engl. *principal component*) (Fulgosi, 1988.) te su izlučeni faktori uz primjenu ortogonalne *varimax* rotacije (Fulgosi, 1988.) i Kaiserovog postupka normalizacije.

U postupku faktorske analize izvršena je specifikacija broja faktora te je broj faktora iznosio 5. Kao ulaz u faktorsku analizu korištene su varijable iz upitnika, 27 varijabli teoretskog modela kriterija odlučivanja za uvođenje e-učenja. Razlog specifikacije broja faktora u faktorskoj analizi bila je postojeća struktura teoretskog modela kriterija odlučivanja za uvođenje e-učenja. U logičkoj strukturi teoretskog modela mogu se prepoznati 5 faktora: *Organizacijska spremnost okruženja*, *Formalno-pravna spremnost okruženja*, *Raspoloživost temeljne ICT infrastrukture*, *Raspoloživost specifične infrastrukture i alata za e-učenje* te *Raspoloživost ljudskih resursa* i *Razvoj ljudskih resursa* koje možemo objediniti jednim faktorom *Ljudski resursi*. Potrebno je napomenuti da je postupak faktorske analize proveden i s drugim faktorskim strukturama (s 3, 4 i 6 faktora), ali uspoređujući različite iteracije, najlogičnijim rješenjem se pokazala petfaktorska struktura, koja je u skladu s teoretskim modelom u upitniku.

Metodom faktorske analize glavnih komponentata uz primjenu ortogonalne *varimax* rotacije, dobiveni su gotovo sukladni faktori strukturi teoretskog modela kriterija odlučivanja za uvođenje e-učenja. Rezultat je pokazao poklapanje u većem dijelu strukture te je opravdao postavljen teoretski model (Tablica 4-15.).

Kako bi se utvrdila pouzdanost teoretskog modela kriterija odlučivanja za uvođenje e-učenja, na osnovi prikupljenih rezultata izračunat je Cronbachov *alpha*-koeficijent za procjenu unutarnje konzistencije rezultata koji iznosi .8927 (za čitav model koji sadrži 27 varijabli).

Nakon toga napravljena je faktorska analiza na N=90 ispitanika. Metodom glavnih komponentata (Fulgosi, 1988.) ekstrahirani su statistički značajni faktori u prostoru varijabli teoretskog modela uz ortogonalni način rotacije (Fulgosi, 1988.) i *varimax* kriterij rotacije. Tijekom faktorske analize dobiven je CMO indeks (Kaiser-Meyer-Olkin indeks, indeks adekvatnosti uzorkovanja) (Fulgosi, 1988.) $K=0,760$.

Tablica 4-14. prikazuje postotke varijance rezultata dobivene postupkom faktorske analize za teoretski model kriterija odlučivanja za uvođenje e-učenja. Druga kolona tablice 4-14. prikazuje karakteristične korijene (tzv. lambda koeficijente) koji iskazuju jačinu pojedinog faktora, treća kolona sadrži postotak varijance kojeg pojedini faktor objašnjava, a četvrta kolona kumulativni postotak varijance. Na osnovu 5 faktora je kumulativno objašnjeno 57,014 % varijance rezultata (prvi faktor objašnjava 16,350 % varijance rezultata, drugi faktor 15,027 %, treći faktor 11,566 %, četvrti faktor 7,931 % i peti faktor 6,141 % od ukupne varijance rezultata).

Tablica 4-14. Postoci varijance rezultata dobiveni postupkom faktorske analize za teoretski model kriterija odlučivanja za uvođenje e-učenja

Faktori	Karakteristični korijen <i>Ukupno</i>	Postotak varijance	Kumulativni postotak varijance
1	2	3	4
F 1 Ljudski resursi	4,414	16,350	16,350
F 2 Specifična infrastruktura za e-učenje	4,057	15,027	31,376
F 3 Temeljna ICT infrastruktura za e-učenje	3,123	11,566	42,942
F 4 Organizacijska spremnost i strateške pretpostavke za uvođenje e-učenja	2,141	7,931	50,873
F 5 Formalno-pravna spremnost za uvođenje e-učenja	1,658	6,141	57,014

N=90

Tablica 4-15. prikazuje rotiranu matricu komponenata s prikazom varijabli teoretskog modela koje imaju najveću projekciju varijance na pojedini faktor. Na osnovu kriterija projekcije varijance varijable na pojedini faktor veličine 0,519 i veći (6 varijabli je isključeno iz modela jer nisu poštivale donju granicu korelacije varijable i faktora koja iznosi 0,519) i/ili kriterija neujednačenih projekcija varijabli na više faktora (5 varijabli (osim varijable *Sustav za zaštitu intelektualnog vlasništva 028*) je ujedno imalo ujednačene projekcije na više faktora), teoretski model je reduciran na 21 varijablu. Varijable koje nisu zadovoljile zadane kriterije su: *Standardizacija 031*, *Izobrazba studenata 050*, *Sustav za zaštitu intelektualnog vlasništva 028*, *Integralni IS 035*, *VLE 037* i *Organizacijska spremnost 026*.

Tablica 4-15. Rotirana matrica komponenata s prikazom projekcije varijance na pojedini faktor za teoretski model kriterija odlučivanja za uvođenje e-učenja

	F 1	F 2	F 3	F 4	F 5
1	2	3	4	5	6
F1 - Ljudski resursi					
Osoblje metodička potpora 046	,848	1,972E-02	9,212E-02	2,953E-02	-4,592E-02
Osoblje tehnička potpora 045	,813	5,701E-02	,106	9,460E-02	,113
Osoblje anim. i video 047	,730	,103	,139	,175	2,880E-02
Usavršavanje pomoćnog osoblja 049	,696	,143	,232	,173	,124
Usavršavanje nastavnika 048	,628	,199	,195	,154	,158
Centar potpore 044	,627	4,231E-03	,217	,189	6,818E-02
Standardizacija 031	,439	,222	,329	-,229	-,108
F 2 - Specifična infrastruktura za e-učenje					
Video i audio streaming 041	-,223	,809	,141	-1,364E-02	,110
Videokonf. sustavi 040	-7,638E-02	,803	,177	,164	,161
Simulacije 043	,246	,773	-5,062E-02	,142	,154
Video i audio materijal 042	,202	,757	,151	4,438E-03	-3,048E-02
Repozitorij 038	,249	,630	,123	,108	-,237
Sustav ispitivanja 039	,138	,580	,317	,128	-,120
Izobrazba studenata 050	,421	,434	-9,030E-02	2,705E-02	,176
F 3 - Temeljna ICT infrastruktura za e-učenje					
Mrežna infrastrukt. 032	,119	,167	,718	,125	2,903E-02
Računalna opremljenost 033	,237	6,207E-02	,646	1,227E-02	-6,103E-03
MLES 036	,226	,247	,619	,327	-,202
Tehnička opremljenost 034	-5,547E-02	,189	,593	-5,800E-02	,553
Sustav za zaštitu intelekt. vlasništva 028	,141	9,095E-03	,480	,107	,285
Integralni IS 035	,269	,315	,458	-,113	-1,579E-02
F 4 - Organizacijska spremnost (strateške pretpostavke) za uvođenje e-učenja					
Strategija fakulteta 025	,194	7,395E-02	3,458E-02	,757	,235
Sveučilišni razvojni okvir 024	8,999E-02	,293	-4,563E-02	,631	-4,075E-02
Financijska spremnost 027	,152	-4,040E-02	,436	,575	,119
VLE 037	,241	,394	,428	,447	-,203
Organizacijska spremnost 026	,413	-2,612E-02	,367	,434	-4,615E-02
F 5 - Formalno-pravna spremnost za uvođenje e-učenja					
Sustav napredovanja nastavnika 029	,110	-8,302E-02	-4,504E-02	5,093E-02	,781
Sustav kontrole kvalitete 030	,310	,241	,115	,199	,519

Nakon isključivanja varijabli koje nisu zadovoljile kriterije, postupak faktorske analize je proveden ponovno na 21 varijabli reduciranog modela. Metodom glavnih komponentata uz ortogonalni način rotacije i *varimax* kriterij rotacije ekstrahirano je 5 identičnih faktora prepoznatih u rezultatu faktorske analize 27 varijabli teoretskog modela kriterija odlučivanja za uvođenje e-učenja (Tablica 4-15.).

Tablica 4-16. prikazuje postotke varijance rezultata dobivene postupkom faktorske analize za reducirani model kriterija odlučivanja za uvođenje e-učenja. Druga kolona tablice 4-16. prikazuje karakteristične korijene (tzv. lambda koeficijente) koji iskazuju jačinu pojedinog faktora, treća kolona sadrži postotak varijance kojeg pojedini faktor objašnjava, a četvrta kolona kumulativni postotak varijance. Na osnovu 5 faktora je kumulativno objašnjeno 63,143 % varijance rezultata (prvi faktor objašnjava 18,961 % varijance rezultata, drugi faktor 17,425 %, treći faktor 10,582 %, četvrti faktor 8,952 % i peti faktor 7,224 % od ukupne varijance rezultata). CMO indeks (Kaiser-Meyer-Olkin indeks) $K=0,769$ svojom vrijednošću ukazuje na dobar uzorak.

Alpha koeficijent pouzdanosti teoretskog modela kriterija odlučivanja za uvođenje e-učenja nakon reduciranja na 21 varijablu iznosi .8686 (N=90). Za pojedine faktore dobiveni su sljedeći *alpha* (α) koeficijenti: FAKTOR 1: $\alpha = .8701$, FAKTOR 2: $\alpha = .8559$, FAKTOR 3: $\alpha = .7048$, FAKTOR 4: $\alpha = .5468$, FAKTOR 5: $\alpha = .3767$. Unatoč relativno niskoj mjeri *alpha* koeficijenata pouzdanosti faktora 5 u odnosu na faktore 1, 2, 3 i 4, faktor je zadržan u daljnjim analizama rezultata. Relativno niska mjera pouzdanosti posljedica je relativno malog broja varijabli kod faktora 5 (2 varijable).

Tablica 4-16. Postoci varijance rezultata dobiveni postupkom faktorske analize za reducirani model kriterija odlučivanja za uvođenje e-učenja

Faktori	Karakteristični korijen <i>Ukupno</i>	Postotak varijance	Kumulativni postotak varijance
1	2	3	4
F 1 Ljudski resursi	3,982	18,961	18,961
F 2 Specifična infrastruktura za e-učenje	3,659	17,425	36,386
F 3 Temeljna ICT infrastruktura za e-učenje	2,222	10,582	46,968
F 4 Organizacijska spremnost i strateške pretpostavke za uvođenje e-učenja	1,880	8,952	55,919
F 5 Formalno-pravna spremnost za uvođenje e-učenja	1,517	7,224	63,143

N=90

Tablica 4-17. prikazuje rotiranu matricu komponenata s prikazom varijabli reduciranog modela koje imaju najveću projekciju varijance na pojedini faktor.

Temeljem rezultata faktorske analize potvrđeno je sljedećih 5 faktora:

- **F 1 - Ljudski resursi**
- **F 2 - Specifična infrastruktura za e-učenje**
- **F 3 - Temeljna ICT infrastruktura za e-učenje**
- **F 4 - Organizacijska spremnost i strateške pretpostavke za uvođenje e-učenja**
- **F 5 - Formalno-pravna spremnost za uvođenje e-učenja.**

Tablica 4-17. Rotirana matrica komponenata s prikazom projekcije varijance na pojedini faktor za reducirani model kriterija odlučivanja za uvođenje e-učenja

	F 1	F 2	F 3	F 4	F 5
1	2	3	4	5	6
F1 - Ljudski resursi					
Osoblje metodička potpora 046	,883	3,415E-02	5,202E-02	-1,120E-02	-4,832E-02
Osoblje tehnička potpora 045	,835	6,881E-02	,119	2,543E-02	,103
Osoblje anim. i video 047	,761	,118	9,200E-02	,105	1,353E-02
Usavršavanje pomoćnog osoblja 049	,709	,146	,164	,196	,106
Centar potpore 044	,652	-1,242E-03	,176	,206	4,064E-02
Usavršavanje nastavnika 048	,610	,175	,139	,238	,156
F 2 - Specifična infrastruktura za e-učenje					
Video i audio streaming 041	-,196	,840	9,800E-02	-1,927E-03	,108
Videokonf. sustavi 040	-5,610E-02	,806	,176	,204	,154
Simulacije 043	,265	,784	-9,944E-02	9,253E-02	,153
Video i audio materijal 042	,214	,769	9,195E-02	-9,597E-03	-4,100E-02
Sustav ispitivanja 039	,160	,609	,254	,136	-,101
Repozitorij 038	,242	,603	,179	9,750E-02	-,276
F 3 - Temeljna ICT infrastruktura za e-učenje					
Mrežna infrastrukt. 032	,163	,193	,778	,107	3,312E-02
Računalna opremljenost 033	,266	,105	,720	-6,693E-02	-1,287E-02
Tehnička opremljenost 034	-3,167E-02	,183	,625	2,887E-02	,564
MLES 036	,268	,233	,528	,417	-,240
F 4 - Organizacijska spremnost (strateške pretpostavke) za uvođenje e-učenja					
Strategija fakulteta 025	,191	3,302E-02	5,800E-02	,792	,154
Sveučilišni razvojni okvir 024	9,796E-02	,282	-,100	,662	-3,168E-02
Financijska spremnost 027	,194	-3,291E-02	,397	,558	7,218E-02
F 5 - Formalno-pravna spremnost za uvođenje e-učenja					
Sustav napredovanja nastavnika 029	,123	-9,182E-02	-4,377E-03	2,484E-02	,807
Sustav kontrole kvalitete 030	,340	,251	6,778E-03	,289	,512

Tablica 4-18. prikazuje usporedbu postavljenog teoretskog modela kriterija odlučivanja za uvođenje e-učenja iz upitnika i faktora koji su ekstrahirani faktorskom analizom u faktorskoj strukturi kriterija odlučivanja za uvođenje e-učenja.

Tablica 4-18. Usporedba postavljenog teoretskog modela kriterija odlučivanja za uvođenje e-učenja iz upitnika i faktora koji su ekstrahirani faktorskom analizom

TEORETSKI MODEL IZ UPITNIKA	FAKTORI DOBIVENI FAKTORSKOM ANALIZOM
<p>RASPOLOŽIVOST LJUDSKIH RESURSA</p> <ul style="list-style-type: none"> Specijalizirani centar potpore e-učenju Raspoloživost pomoćnog osoblja za tehničku potporu e-učenju Raspoloživost pomoćnog osoblja za metodičku potporu e-učenju Raspoloživost pomoćnog osoblja za grafičko oblikovanje, animaciju i video 	<p>F 1– LJUDSKI RESURSI</p> <ul style="list-style-type: none"> Specijalizirani centar potpore e-učenju Raspoloživost pomoćnog osoblja za tehničku potporu e-učenju Raspoloživost pomoćnog osoblja za metodičku potporu e-učenju Raspoloživost pomoćnog osoblja za grafičko oblikovanje, animaciju i video
<p>RAZVOJ LJUDSKIH RESURSA</p> <ul style="list-style-type: none"> Sustav kontinuiranog usavršavanja nastavnog osoblja Sustav kontinuiranog usavršavanja pomoćnog osoblja 	<ul style="list-style-type: none"> Sustav kontinuiranog usavršavanja nastavnog osoblja Sustav kontinuiranog usavršavanja pomoćnog osoblja <p>F 2 – SPECIFIČNA INFRASTRUKTURA ZA E-UČENJE</p>
<p>RASPOLOŽIVOST SPECIFIČNE INFRASTRUKTURE I ALATA ZA E-UČENJE</p> <ul style="list-style-type: none"> Integralni sustav upravljanja procesom obrazovanja – <i>Managed learning environments</i> Virtualno edukacijsko okružje – <i>Virtual Learning Environment</i> Repozitorij digitalnog obrazovnog materijala Sustav ispitivanja uz pomoć računala Mrežni videokonferencijski sustavi Video i audio streaming Proizvodnja video i audio materijala Sustavi za simulacije i virtualnu stvarnost 	<ul style="list-style-type: none"> Repozitorij digitalnog obrazovnog materijala Sustav ispitivanja uz pomoć računala Mrežni videokonferencijski sustavi Video i audio streaming Proizvodnja video i audio materijala Sustavi za simulacije i virtualnu stvarnost <p>F 3 - TEMELJNA ICT INFRASTRUKTURA ZA E-UČENJE</p> <ul style="list-style-type: none"> Mrežna infrastruktura (<i>on campus, off campus</i>) Računalna opremljenost nastavnika i studenata Integralni sustav upravljanja procesom obrazovanja – <i>Managed learning environments</i>
<p>RASPOLOŽIVOST TEMELJNE ICT INFRASTRUKTURE</p> <ul style="list-style-type: none"> Mrežna infrastruktura (<i>on campus, off campus</i>) Računalna opremljenost nastavnika i studenata Tehnička opremljenost predavaonica i učionica na sveučilištu/fakultetu Integralni informacijski sustav sveučilišta/fakulteta 	<ul style="list-style-type: none"> Tehnička opremljenost predavaonica i učionica na sveučilištu/fakultetu <p>F 4 - ORGANIZACIJSKA SPREMNOST (strateške pretpostavke) ZA UVOĐENJE E-UČENJA</p> <ul style="list-style-type: none"> Razvojna strategija fakulteta - podrška fakulteta razvojnim smjernicama Sveučilišni razvojni okvir - razvojna strategija obrazovanja na sveučilištu Financijska spremnost sveučilišta/fakulteta za uvođenje e-učenja
<p>ORGANIZACIJSKA SPREMNOST OKRUŽENJA</p> <ul style="list-style-type: none"> Sveučilišni razvojni okvir – razvojna strategija obrazovanja na sveučilištu Razvojna strategija fakulteta – podrška fakulteta razvojnim smjernicama Financijska spremnost sveučilišta/fakulteta za uvođenje e-učenja 	<p>F 5 - FORMALNO-PРАВNA SPREMNOST ZA UVOĐENJE E-UČENJA</p> <ul style="list-style-type: none"> Sustav i kriteriji napredovanja sveučilišnih nastavnika Sustav vrednovanja i kontrole kvalitete na sveučilištu/fakultetu
<p>FORMALNO-PРАВNA SPREMNOST OKRUŽENJA</p> <ul style="list-style-type: none"> Sustav za zaštitu intelektualnog vlasništva na državnoj i akademskoj razini Sustav i kriteriji napredovanja sveučilišnih nastavnika Sustav vrednovanja i kontrole kvalitete na sveučilištu/fakultetu Standardizacija digitalnih obrazovnih materijala 	

4.4.3. Rezultati klasteriranja metodom k srednjih vrijednosti

Metoda klasteriranja korištena je u analizi ispitanika, kako bi se ispitanici grupirali u određeni broj klastera (prema sličnosti mišljenja o zadanom problemu), koji zadovoljavaju dva osnovna kriterija:

- Svaki klaster predstavlja homogen skup: primjeri koji pripadaju istoj grupi su međusobno slični i
- Svaki klaster mora se razlikovati od ostalih klastera, tj. primjeri koji pripadaju određenom klasteru značajno se razlikuju od primjera koji pripadaju ostalim klasterima.

Algoritam k -srednjih vrijednosti je iterativna procedura u kojoj je na početku definirana ulazna vrijednost odnosno broj grupa - k segmenata/klastera. Ako je broj grupa k u metodi k srednjih vrijednosti pogrešno odabran, konačni rezultati neće biti dobri. Ispravan pristup odabiru broja grupa je eksperimentiranje s različitim brojem grupa. Postupak klasteriranja metodom k srednjih vrijednosti proveden je s različito definiranim brojem klastera: $k=3,4,5,6$. Najlogičniji rezultati dobiveni su u varijaciji u kojoj je broj segmenata bio 4 i to nakon što su 2 slučaja (2 upitnika) bila izbačena jer su u svakoj varijaciji narušavali skladnost klastera svojim nesvrstanošću.

Ispitanici su grupirani u 4 klastera prema sličnosti ocjena važnosti koje su dodijelili varijablama u anketi. Ispitanici sa sličnim mišljenjem odredili su tzv. centroid koji odražava ključne karakteristike svakog klastera. Centroid je točka u prostoru primjera, koja ustvari reprezentira srednju ili prosječnu lokaciju određene grupe primjera. Koordinate ove točke izračunate su kao prosječne vrijednosti koordinata svih primjera koji pripadaju toj grupi, tj. centroid je težište promatranog skupa točaka. Iterativna procedura redefiniranja centroida te raspoređivanja primjera u odgovarajuće grupe zahtijeva obično samo nekoliko iteracija do zadovoljavajuće konvergencije. U tablici 4-19. može se vidjeti 5 iteracija koje su bile potrebne u ovom slučaju. Postupak se ponavljao dok se svaki slučaj nije svrstao u klaster koji mu je prema određenim svojstvima najbliži. Na početku se metodom slučajnog izbora uzme nekoliko točaka u prostoru, već spomenutih centroida koji označavaju sredinu nekog klastera. Nakon toga

se za svaki zapis izračuna udaljenost prema svakom centroidu i odredi se koji mu je centroid najbliži. Smještanje ispitanika u pojedini klaster, algoritam procjenjuje na temelju euklidske funkcije udaljenosti (kvadratni korijen zbroja kvadrata udaljenosti po svim koordinatama (atributima) prostora). Time je svaki pojedini slučaj svrstan u određeni klaster. Zatim se za svaki novi klaster izračunava njegov centroid, tako da se izračunaju sredina ili prosjek svake točke u prostoru pojedinog klastera, uzimajući u obzir svaku dimenziju. Preciznije možemo reći da se koordinate ove točke izračunavaju kao prosječne vrijednosti koordinata svih primjera koji pripadaju toj grupi. Proces pridruživanja točaka u prostoru pojedinom klasteru i izračunavanje novog centroida ponavlja se dok se ne prestanu mijenjati granice koje omeđuju pojedine klastere.

Tablica 4-19. Broj iteracija potrebnih u provedenom klasteriranju metodom k srednjih vrijednosti

Iteracija	Promjene u centrima klastera			
	1	2	3	4
1	3,798	4,308	3,666	3,650
2	,559	,925	,262	,803
3	,000	,000	,181	,842
4	,000	,000	,197	,573
5	,000	,000	,000	,000

**Convergence achieved due to no or small distance change. The maximum distance by which any center has changed is ,000. The current iteration is 5. The minimum distance between initial centers is 7,141.*

Prema opisanom postupku, elementi se u iterativnim procesima vežu uz centralne vrijednosti klastera, klasteriranje svakom slučaju dodjeljuje vrijednost pripadnosti klastera, te opcionalno pridružuje vrijednosti udaljenosti od centra klastera. Pripadnost slučaja pojedinom klasteru i njihova udaljenost od centroida odnosno centra klastera može se vidjeti u tablici 4-20. za 88 slučajeva. U tablici 4-21. izdvojeni su slučajevi najmanje udaljenosti od centra pripadajućeg klastera, koji se mogu interpretirati kao slučajevi koji svojim karakteristikama nabolje predstavljaju klaster kojem pripadaju. U prilogu 1 nalazi se popis ispitanika po klasterima.

Tablica 4-20. Pripadnost slučajeva pojedinom klasteru

Broj slučaja	Klaster	Udaljenost
1	3	2,335
2	3	3,395
3	3	2,584
4	3	2,335
5	3	3,128
6	3	2,128
7	3	2,011
8	3	2,703
9	3	3,406
10	2	3,240
11	3	2,057
12	4	2,643
13	2	2,983
14	3	2,335
15	1	2,955
16	3	2,661
17	3	3,576
18	2	2,665
19	1	3,603
20	3	3,465
21	3	3,539
22	4	4,948
23	3	3,181
24	3	2,230
25	4	3,100
26	3	2,964
27	1	4,121
28	3	2,489
29	3	2,481
30	3	2,895
31	2	5,128
32	3	2,221
33	3	3,307
34	3	3,323
35	3	2,869
36	4	3,257
37	3	2,737
38	4	2,690
39	3	3,087
40	4	2,997
41	4	2,781
42	3	2,179
43	3	3,565
44	3	2,875
45	4	4,014

Broj slučaja	Klaster	Udaljenost
46	4	2,870
47	2	3,834
48	3	2,335
49	2	2,950
50	3	2,057
51	4	2,522
52	4	4,357
53	3	2,964
54	4	3,773
55	1	3,238
56	3	2,770
57	3	1,766
58	3	2,576
59	3	2,654
60	3	5,071
61	1	3,706
62	1	3,276
63	2	4,528
64	3	2,716
65	3	2,696
66	3	3,728
67	1	3,839
68	4	3,314
69	3	3,210
70	3	3,323
71	3	2,914
72	3	3,038
73	3	2,598
74	4	2,147
75	3	2,757
76	2	3,507
77	3	2,504
78	3	3,663
79	3	3,169
80	1	2,595
81	4	3,756
82	2	3,564
83	3	2,230
84	4	4,121
85	3	2,784
86	3	2,654
87	2	2,302
88	3	2,335

Tablica 4-21. Slučajevi najmanje udaljenosti od centra klastera

Klaster	Slučaj	Udaljenost od centra
1	80	2,595
2	87	2,302
3	57	1,766
4	74	2,147

U tablici 4-22. vide se rezultati finalne klasterizacije koja je interpretirana preko slike 4-15., na kojoj su izdvojene varijable čije niže ili više ocjene su značajne za ocrtavanje klastera. Ispitanici su prema sličnosti ocjena važnosti koje su davali varijablama u anketi, raspoređeni u četiri klastera ($k=4$) koji su nakon analize ocjena varijabli po klasterima (analiza prema tablici x4) nazvani:

1. klaster: STUDENTSKO GLEDIŠTE
2. klaster: GLEDIŠTE OSOBLJA ZA POTPORU
3. klaster: STRATEŠKO GLEDIŠTE
4. klaster: TEHNOLOŠKO GLEDIŠTE.

Na slici 4-15. je prikazana matrica klastera, te su navedene varijable (reducirani broj varijabli faktorskom analizom, ukupno 21 varijabla) koje su ocjenjene nižim i višim ocjenama od strane ispitanika i na taj način su okarakterizirale svaki od 4 navedena klastera.


Broj slučajeva, elemenata (n) u svakom od klastera može se vidjeti u tablici 4-23. Klaster kojem pripada najveći broj slučajeva je klaster *Strateško gledište* s 54 slučajeva ($n=54$), što pokazuje i da je uzorak ispitanika dobro izabran jer su ispitanici koji su sudjelovali u istraživanju, svojim rezultatima dali doprinos izradi strategije e-učenja Sveučilišta u Zagrebu.

Tablica 4-22. Finalna klasterizacija

	Klaster			
	1	2	3	4
Sveučilišni razvojni okvir 024	4	4	5	4
Strategija fakulteta 025	4	5	5	4
Financijska spremnost 027	4	4	4	4
Sustav napredovanja nastavnika 029	3	5	4	4
Sustav kontrole kvalitete 030	4	4	4	4
Mrežna infrastruktura 032	4	4	5	5
Računalna opremljenost 033	4	4	5	4
Tehnička opremljenost 034	4	4	4	5
MLES 036	4	3	4	4
Repozitorij 038	3	3	4	4
Sustav ispitivanja 039	3	2	4	4
Videokonf. sustavi 040	3	2	4	4
Video i audio streaming 041	4	2	4	3
Video i audio materijal 042	3	2	4	4
Simulacije 043	2	2	4	3
Centar potpore 044	4	5	5	4
Osoblje tehnička potpora 045	3	5	5	4
Osoblje metodička potpora 046	3	5	4	4
Osoblje animacija i video 047	3	4	4	4
Usavršavanje nastavnika 048	4	5	5	5
Usavršavanje pomoćnog osoblja 049	3	5	4	4

Tablica 4-23. Broj slučajeva u svakom od klastera

	Klaster	Broj slučajeva
Klaster	1	8,000
	2	10,000
	3	54,000
	4	16,000
Vrijedi		88,000
Nedostaje		,000



Slika 4-14. Matrica klastera

Udaljenost između centara finalnih klastera je prikazana u tablici 4-24., te se vidi da je najveća udaljenost (udaljenost=4,661) između klastera 1 (*Studentsko gledište*) i 3 (*Strateško gledište*) što je naravno samo po sebi razumljivo te govori u prilog ispravnosti interpretacije klastera.

Tablica 4-24. Udaljenost između centara finalnih klastera

Klaster	1	2	3	4
1		4,459	4,661	3,453
2	4,459		4,544	4,001
3	4,661	4,544		2,281
4	3,453	4,001	2,281	

5. ANALITIČKI HIJERARHIJSKI PROCES (AHP METODA)

U petom poglavlju su opisani metodološki i matematički temelji AHP metode te razvoj i testiranje AHP modela za donošenje odluke o uvođenju e-učenja u visoko školstvo na razini katedre i/ili kolegija. U prvom djelu petog poglavlja daje se pregled primjena AHP metode, navode se prednosti i nedostaci AHP metode te se daje uvid u najpoznatiju računalnu podršku AHP metodi – programski alat *Expert Choice*. U drugom djelu petog poglavlja prikazan je proces razvoja AHP modela za donošenje odluke o uvođenju e-učenja na razini katedre i/ili kolegija koji se temelji na rezultatima faktorske analize provedene na podacima prikupljenim anketom. Testiranje modela izvršeno je grupnim odlučivanjem o obliku uvođenja e-učenja na kolegij Matematika, na Katedri za kvantitativne metode, na Fakultetu organizacije i informatike.

5.1. Temelji AHP metode

Metoda Analitički hijerarhijski proces (engl. AHP - *The Analytic Hierarchy Process*) spada u najpoznatije i posljednjih godina najviše korištene metode za odlučivanje kada se proces odlučivanja, odnosno izbor neke od raspoloživih alternativa ili njihovo rangiranje, temelji na više atributa koji imaju različitu važnost i koji se izražavaju pomoću različitih skala. AHP metoda omogućava fleksibilnost procesa odlučivanja i pomaže donositeljima odluka da postave prioritete i donesu kvalitetnu odluku uzevši u obzir i kvalitativne i kvantitativne aspekte odluke (Saaty, 1991.).

Široki spektar primjena AHP metode, o kojima će više biti riječi u točki 5.1.4., dovoljan je dokaz da je AHP metoda danas jedna od najpopularnijih i najčešće korištenih metoda za višekriterijsko odlučivanje u rješavanju realnih problema. Primjenjuje se u odlučivanju, evaluaciji, alokaciji resursa, planiranju i razvoju, ali i u područjima kao što su industrija, inženjerstvo, politika, obrazovanje te mnoga druga.

AHP model, razvijen u okviru ove doktorske disertacije, služi kao potpora u donošenju odluke o uvođenju e-učenja u visoko školstvo na razini katedre i/ili kolegija. Izvornost ovog modela je u kombiniranoj metodi kojom je razvijen te u problemu strateškog planiranja i odlučivanja o uvođenju e-učenja, u čijem rješavanju pomaže.

5.1.1. Metodološki temelj AHP metode

AHP metodu je razvio Thomas Saaty početkom sedamdesetih godina dvadesetog stoljeća (Saaty, 1977., 1980.), a ona predstavlja vrlo važnu metodu za odlučivanje koja ima svoju primjenu u rješavanju kompleksnih problema čije elemente čine ciljevi, kriteriji, podkriteriji i alternative. O važnosti Analitičkog hijerarhijskog procesa (AHP) dovoljno govori činjenica da je metoda detaljno proučavana i unapređivana putem mnogih znanstvenih radova na prestižnim svjetskim sveučilištima (poglavlje 5.1.4.) te da se svake dvije godine održava međunarodna znanstvena konferencija ISAHP posvećena AHP metodi i njenim primjenama (International Conference on Analytic Hierarchy Process, 2007.).

AHP metoda ima veliku važnost u strukturiranju problema i procesu donošenja odluke. Primjenom AHP metode omogućava se interaktivno kreiranje hijerarhije problema koja služi kao priprema scenarija odlučivanja, zatim se vrši uspoređivanje u parovima elemenata hijerarhije (ciljeva, kriterija i alternativa) u *top-down* ili *bottom-up* smjeru, te se na kraju vrši sinteza svih uspoređivanja i određuju se težinski koeficijenti svih elemenata hijerarhije (normiranje). Zbroj težinskih koeficijenata elemenata na svakoj razini hijerarhije jednak je 1 i omogućava donositelju odluke da rangira sve elemente hijerarhije po važnosti.

AHP omogućava i interaktivnu analizu osjetljivosti. Preko analize osjetljivosti sagledava se kako promjene ulaznih podataka utječu na izlazne rezultate. U analizi osjetljivosti mogu se simulirati važnosti kriterija/podkriterija i promatrati promjene u rangovima alternativa. Analiza se može izvesti iz cilja ili bilo kojeg drugog objekta u hijerarhiji kako bi se utvrdilo da li je rang lista alternativa dovoljno stabilna u odnosu na prihvatljive promjene ulaznih podataka. Ukoliko se promjenom ulaznih podataka za 5% u svim mogućim kombinacijama, ne promijeni rang alternativa, smatra se da je postignuta stabilnost rezultata (Bayazit, 2005.).

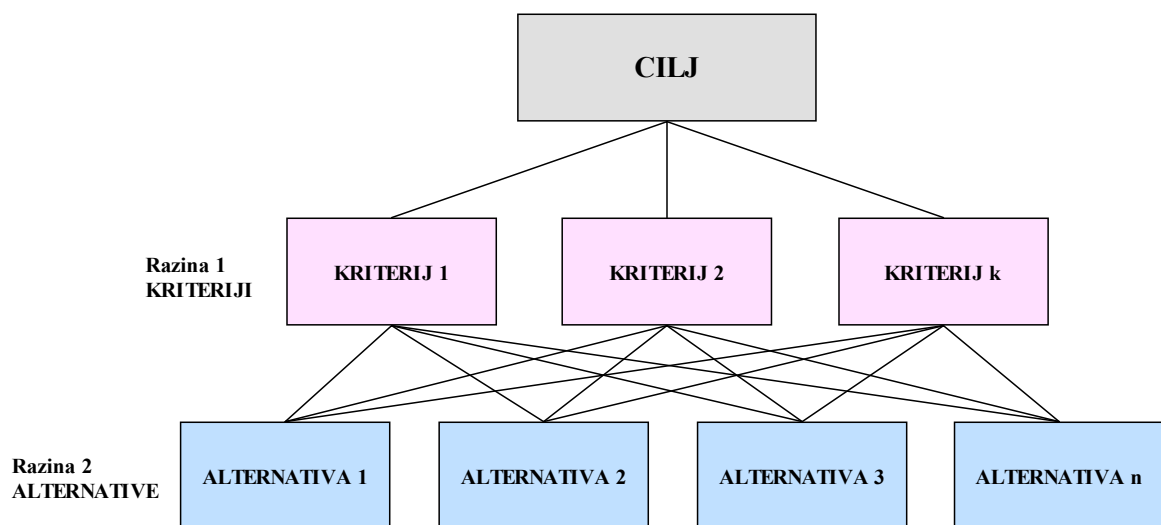
Vrlo važna značajka u primjeni AHP metode je i provjera konzistentnosti procjena donositelja odluke. Tijekom uspoređivanja u parovima elemenata hijerarhije, sve do kraja procedure i sinteze rezultata, provjerava se konzistentnost procjena donositelja odluke i utvrđuje ispravnost dobivenih težinskih koeficijenata kriterija i prioriteta alternativa. Detaljnije o konzistentnosti procjena donositelja odluke u poglavlju 5.1.2.1.

Primjena AHP metode može se objasniti u četiri osnovna koraka (Saaty, 1980.):

1. Razvije se hijerarhijski model problema odlučivanja s ciljem na vrhu, kriterijima i podkriterijima na nižim razinama, te alternativama na dnu modela. Na slici 5-1. prikazan je hijerarhijski model u dvije razine koju čine cilj, kriteriji i alternative.
2. Na svakoj razini hijerarhijske strukture u parovima se međusobno uspoređuju elementi te strukture, pri čemu se preferencije donositelja odluke izražavaju uz pomoć Saatyjeve skale relativne važnosti koja ima 5 stupnjeva i 4 međustupnja verbalno opisanih intenziteta i odgovarajuće numeričke vrijednosti u rasponu od 1-9 (Saaty, 1980., 1991.) (Tablica 5-1.).
3. Iz procjena relativnih važnosti elemenata odgovarajuće razine hijerarhijske strukture problema pomoću matematičkog modela izračunavaju se lokalni prioriteti (težine) kriterija, podkriterija i alternativa, koji se zatim sintetiziraju u ukupne prioritete alternativa. Ukupni prioritet pojedine alternative izračunava se tako da se zbroje njezini lokalni prioriteti ponderirani s težinama elemenata više razine.
4. Provodi se analiza osjetljivosti.

Metodološki promatrano, rješavanje složenih problema odlučivanja pomoću ove metode temelji se na njihovoj dekompoziciji u hijerarhijsku strukturu čiji elementi su cilj, kriteriji (podkriteriji) i alternative. Cilj se nalazi na vrhu hijerarhije, dok su kriteriji, podkriteriji i alternative na nižim razinama. Kompleksnost problema raste s brojem kriterija i s brojem alternativa. Sposobnost ljudskog uma u međusobnom razlikovanju velikog broja alternativa i kriterija je ograničena, te se u skladu s time, pri formiranju hijerarhije ne preporuča više od 5 ± 2 elemenata na istoj razini.

Raščlanjivanje složenih problema na jednostavnije koji se grupiraju po određenoj logici međusobne sličnosti, prirodan je način djelovanja ljudskog uma. Slika 5-1. prikazuje primjer hijerarhije u dvije razine koju čine cilj, kriteriji i alternative.



Slika 5-1. Hijerarhijski model – AHP struktura (Dyer, 1991., Saaty, 1991.)

Druga važna komponenta AHP metode je matematički model pomoću kojeg se računaju prioriteti (težine) elemenata (poglavlje 5.1.2.). Donositelj odluke uspoređivanjem elemenata u parovima na istoj razini hijerarhijske strukture, koristi svoje subjektivne procjene koje se temelje na prethodnom znanju i vlastitom iskustvu. Potrebno je ukupno $n \times (n-1)/2$ usporedbi što znači da je broj usporedbi proporcionalan kvadratu broja elemenata koji se uspoređuju. Isti postupak se primjenjuje kroz cijelu hijerarhiju, sve dok se na posljednjoj razini k ne izvrše usporedbe svih alternativa u odnosu na nadređene podkriterije na preposljednjem $(k-1)$ -vom nivou. Matematičkim modelom, opisanim detaljnije u poglavlju 5.1.2., sintetizira se konačan rezultat prioriteta alternativa u odnosu na postavljeni cilj problema odlučivanja. Pri uspoređivanju u parovima, koristi se već spomenuta Saatyeva skala relativne važnosti (Saaty, 1980., 1991.) (Tablica 5-1.) koja se sastoji od devet stupnjeva, što je iskustvom, dokazana razumna i održiva razina do koje pojedinac može razlikovati intenzitet odnosa između dva elementa. Neparnim brojevima pridružene su osnovne vrijednosti, dok parni opisuju njihove međuvrijednosti. Ukoliko se želi preciznije izraziti razlika u važnosti elemenata mogu se koristiti i decimalne vrijednosti od 1.1 do 1.9.

Tablica 5-1. Saaty-eva skala relativne važnosti (Saaty, 1980., 1991.)

Intenzitet važnosti	Definicija	Objašnjenje
1	Jednako važno	Dvije aktivnosti jednako doprinose cilju.
3	Umjereno važnije	Na temelju iskustva i procjena, daje se umjerena prednost jednoj aktivnosti u odnosu na drugu.
5	Strogo važnije	Na temelju iskustva i procjena, strogo se favorizira jedna aktivnost u odnosu na drugu.
7	Vrlo stroga, dokazana važnost	Jedna aktivnost izrazito se favorizira u odnosu na drugu, njezina dominacija dokazuje se u praksi.
9	Ekstremna važnost	Dokazi na temelju kojih se favorizira jedna aktivnost u odnosu na drugu, potvrđeni su s najvećom uvjerenjivošću.
2,4,6,8	Međuvrijednosti	
1.1 – 1.9	Decimalne vrijednosti	Pri usporedbi aktivnosti koje su po važnosti blizu jedna drugoj, potrebne su decimalne vrijednosti kako bi se preciznije izrazila razlika u njihovoj važnosti.

Za bolje razumijevanje AHP metode, važno je navesti aksiome na kojima se AHP metoda zasniva (Harker, Vargas, 1987.):

1. *Aksiom recipročnosti.* Ako je element A n puta značajniji od elementa B, tada je element B $1/n$ puta značajniji od elementa A.
2. *Aksiom homogenosti.* Usporedba ima smisla jedino ako su elementi usporedivi – npr. ne može se uspoređivati težina komarca i težina slona.
3. *Aksiom zavisnosti.* Dozvoljava se usporedba među grupom elemenata jednog nivoa u odnosu na element višeg nivoa, tj. usporedbe na nižem nivou zavise od elementa višeg nivoa.
4. *Aksiom očekivanja.* Svaka promjena u strukturi hijerarhije zahtjeva ponovno računanje prioriteta u novoj hijerarhiji.

Postupak za računanje težina kriterija i prioriteta alternativa iz usporedbi elemenata u parovima sadrži tri osnovna koraka: formiranje matrice omjera prioriteta (težina), formiranje normalizirane matrice i izračunavanje težina kriterija i prioriteta alternativa.







Prvi korak je formiranje matrice omjera prioriteta (težina). U i -tom redu i j -tom stupcu te matrice nalazi se vrijednost procijenjenog omjera prioriteta alternativa. Ukoliko se daju procjene relativnih važnosti kriterija, onda je to vrijednost omjera njihovih težina.

Navodi se jednostavan primjer uspoređivanja veličine jabuka. Imamo tri jabuke različitih veličina: Jabuka A, Jabuka B i Jabuka C (Tablica 5-2.–5-4.). Njihova relativna veličina se procjenjuje formiranjem omjera na temelju uspoređivanja u parovima (Saaty predavanja Katz, 2008., Saaty, 2004., Saaty 2005c).

Tablica 5-2. Formiranje omjera uspoređivanjem elemenata u parovima

Usporedba veličine	Jabuka A	Jabuka B	Jabuka C
Jabuka A	S_1 / S_1	S_1 / S_2	S_1 / S_3
Jabuka B	S_2 / S_1	S_2 / S_2	S_2 / S_3
Jabuka C	S_3 / S_1	S_3 / S_2	S_3 / S_3

Tablica 5-3. Omjeri dobiveni uspoređivanjem elemenata u parovima

Usporedba veličine	Jabuka A	Jabuka B	Jabuka C	Vektor prioriteta	Relativna a veličina
 Jabuka A					
 Jabuka B	1	2	6	6/10	A
 Jabuka C	1/2	1	3	3/10	B
	1/6	1/3	1	1/10	C
	Σ 10/6	10/3	10		

Drugi korak je formiranje normalizirane matrice, na način da se izračunaju sume stupaca te da se svaki element prethodne matrice podijeli sa sumom stupca kojem pripada.

Tablica 5-4. Normalizirana matrica i prioriteta alternativa

Usporedba veličine	Jabuka A	Jabuka B	Jabuka C	Prioritet
Jabuka A	6/10	6/10	6/10	0,6
Jabuka B	3/10	3/10	3/10	0,3
Jabuka C	1/10	1/10	1/10	0,1

Treći korak je izračunavanje težina kriterija i prioriteta alternativa. Težine (prioriteti) se izračunavaju kao prosječne vrijednosti elemenata pojedinih redova (Tablica 5-4.):

$$= (6/10+6/10+6/10)/3 = 0,6$$

$$= (3/10+3/10+3/10)/3 = 0,3$$

$$= (1/10+1/10+1/10)/3 = 0,1$$

Vidi se da zbroj ovih težina iznosi 1. Izračunate vrijednosti odgovaraju prioritetima alternativa. Ovaj postupak daje točne vrijednosti prioriteta alternativa, ali samo u slučaju konzistentnih procjena omjera veličina (kao u navedenom slučaju (Tablica 5-3.)). Opisani postupak ne omogućava kontrolu konzistentnosti procjena donositelja odluke.

5.1.2. Matematički temelj AHP metode

U objašnjenju drugog i trećeg koraka AHP metode (uspoređivanja elemenata na svakoj razini hijerarhijske strukture i izračunavanja težinskih koeficijenata i prioriteta), koristit će se matematička notacija.

Neka je n broj kriterija (ili alternativa) čije težine (prioritete) w_i treba odrediti na temelju procjene vrijednosti njihovih omjera koji se označavaju s $a_{ij} = w_i/w_j$. Od omjera relativnih važnosti a_{ij} formira se matrica relativnih važnosti A:

$$A = \begin{bmatrix} w_1/w_1 & w_1/w_2 & \dots & w_1/w_n \\ w_2/w_1 & w_2/w_2 & \dots & w_2/w_n \\ \dots & \dots & \dots & \dots \\ w_n/w_1 & w_n/w_2 & \dots & w_n/w_n \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{bmatrix}$$

Matrica A za slučaj konzistentnih procjena za koje vrijedi $a_{ij} = a_{ik} a_{kj}$ zadovoljava jednadžbu $Aw = nw$, gdje je w vektor (jednostupčana matrica) prioriteta:

$$\begin{bmatrix} w_1/w_1 & w_1/w_2 & \dots & w_1/w_n \\ w_2/w_1 & w_2/w_2 & \dots & w_2/w_n \\ \dots & \dots & \dots & \dots \\ w_n/w_1 & w_n/w_2 & \dots & w_n/w_n \end{bmatrix} \cdot \begin{bmatrix} w_1 \\ w_2 \\ \dots \\ w_n \end{bmatrix} = n \cdot \begin{bmatrix} w_1 \\ w_2 \\ \dots \\ w_n \end{bmatrix}$$

Problem rješavanja težina može se riješiti kao problem rješavanja matrice jednadžbe po jednostupčanoj matrici w za rješenje svojstvene vrijednosti λ različito od 0 to jest:

$$A w = \lambda w$$

Matrica A ima neka posebna svojstva, ona je pozitivna, recipročna matrica $a_{ij} = 1/a_{ji}$ ranga $r(A)=1$ (svi njezini redovi proporcionalni su prvom redu), zbog čega je samo jedna njezina svojstvena vrijednost različita od 0 i jednaka je n (sve ostale svojstvene vrijednosti su jednake 0).

Budući da je suma svojstvenih vrijednosti pozitivne matrice jednaka tragu te matrice, tj. sumi na dijagonali, svojstvena vrijednost različita od nule ima vrijednost n :

$$\lambda_{max} = n .$$

Ukoliko matrica A sadrži nekonzistentne procjene (u praktičnim primjerima gotovo uvijek je tako), vektor težina w može se dobiti rješavanjem jednadžbe:

$$(A - \lambda_{\max} I)w = 0 \text{ uz uvjet } \sum w_i = 1,$$

gdje je λ_{\max} najveća svojstvena vrijednost matrice A

ili

$$Aw = nw \Rightarrow \sum_j a_{ij} w_j = n w_i$$

odakle je

$$w_i = \frac{1}{n} \sum_j a_{ij} w_j \quad \text{za } i = 1, 2, \dots, n.$$

Zbog

$$\sum_i a_{ij} = \frac{w_1 + w_2 + \dots + w_n}{w_j}$$

vrijedi

$$w_j = \frac{1}{\sum_i a_{ij}}$$

težina pojedine alternative w_i je prema tome

$$w_i = \frac{1}{n} \sum_j \frac{a_{ij}}{\sum_t a_{tj}}.$$

Sinteza prioriteta vrši se na način da se lokalni prioriteti alternativa ponderiraju s težinama svih čvorova kojima pripadaju od najniže razine hijerarhijske strukture prema vrhu, a zatim se ti globalni prioriteti za najvišu razinu zbroje te se konstruira ukupni prioritet za pojedinu alternativu.

Zbog svojstava matrice A vrijedi $\lambda_{\max} \geq n$, a razlika $\lambda_{\max} - n$ koristi se u mjerenju konzistencije procjena. U slučaju nekonzistentnosti, što je λ_{\max} bliža n , prosudba je konzistentnija.

5.1.2.1. Matematička svojstva AHP metode

U ovom poglavlju će se navesti najvažniji matematički rezultati iz matričnog računa koji su važni za teorijsko utemeljenje AHP metode. Iz tih rezultata proizlazi da su principi na kojima se temelji AHP metoda sukladni teorijskim rezultatima u području linearne algebre, tj. da se AHP metoda temelji na racionalnom matematičkom modelu. Svojstva koja se prikazuju ne dokazuju se, ali se komentira njihova važnost za AHP metodu.

Pokazano je da je vektor težina kriterija w povezan s matricom njihovih omjera A jednadžbom

$$(1) \quad Aw = nw.$$

Najvažniji teorem na kojem je utemeljena AHP metoda je Perron –Frobeniusov teorem.

Definicija 1: Kvadratna nenegativna matrica A zove se primitivna ako postoji pozitivan broj k takav da je $A^k > 0$.

Jasno je da je matrica relativnih omjera važnosti A primitivna jer je pozitivna.

Definicija 2: Neka je A kvadratna matrica reda n . Rješenje jednadžbe $\det(A - nI) = 0$ zove se svojstvena vrijednost matrice A .

Definicija 3: Neka je λ svojstvena vrijednost matrice A . Vektor x za koji vrijedi $Ax = \lambda x$ zove se svojstveni vektor matrice A .

Rješavanje jednadžbe iz prethodne definicije svodi se na traženje nultočki polinoma n -tog reda. Općenito, rješenja takvog polinoma mogu biti i realna i kompleksna. Sa stajališta AHP modela potrebno je pokazati koji su uvjeti egzistencije realnih rješenja. To je smisao slijedećeg teorema:

Teorem (Perron-Frobenius): Ako je A primitivna matrica reda n , tada za nju vrijedi

- (i) njezina najveća svojstvena vrijednost λ_{\max} je pozitivna
- (ii) svojstveni vektor pridružen toj svojstvenoj vrijednosti ima sve komponente pozitivne
- (iii) modul svake druge svojstvene vrijednosti strogo je manji od najveće svojstvene vrijednosti.

Matrica omjera važnosti koji se dobiju uspoređivanjem u parovima osim što je primitivna ima i dodatna svojstva koja su važna za AHP metodu. Za razumijevanje tih svojstava uvode se sljedeće definicije:

Definicija: Kvadratna pozitivna matrica A zove se recipročna ako vrijedi

- (i) $a_{ii} = 1$
- (ii) $a_{ij} = 1/a_{ji}$

Definicija: Kvadratna pozitivna matrica A zove se recipročno uniformna ako vrijedi

- (i) $a_{ii} = 1$
- (ii) $a_{ij} = 1/a_{ji}$
- (iii) $a_{ij} = a_{ik} \cdot a_{kj}$

Svojstva recipročno uniformne matrice:

- (1) rang recipročno uniformne matrice je 1
- (2) njezina najveća svojstvena vrijednost $\lambda_{\max} = n$
- (3) ako je svojstveni vektor koji pripada najvećoj svojstvenoj vrijednosti $w = (w_1, w_2, \dots, w_n)$, tada vrijedi $a_{ij} = w_i / w_j$

Svojstvo (1) jednostavno se dokazuje ako se uoči da svi su redovi u recipročno uniformnoj matrici proporcionalni njezinom prvom redu. Svojstvo (2) važno je za razumijevanje mjere inkonzistencije. Naime, poznato je da za svojstvene vrijednosti matrice vrijedi $\lambda_{\max} + \lambda_2 + \dots + \lambda_n = tr(A)$, a iz toga, imajući na umu da su dijagonalni elementi te matrice jednaki 1, proizlazi $\lambda_{\max} + \lambda_2 + \dots + \lambda_n = n$. Budući da je broj ne-nul svojstvenih vrijednosti jednak rangu matrice, proizlazi da je $\lambda_{\max} = n$.

Mjera inkonzistencije procjena:

Ukoliko procjene relativnih omjera važnosti koje sadrži matrica A nisu konzistentne, tj. ne vrijedi svojstvo (iii) iz definicije recipročno uniformne matrice, najveća svojstvena vrijednost ostaje i dalje realna, ali vrijedi $\lambda_{\max} > n$. Zbog toga i zbog $\lambda_{\max} + \lambda_2 + \dots + \lambda_n = tr(A)$ proizlazi

$|\lambda_2 + \dots + \lambda_n| = \lambda_{\max} - n$. Na ovoj jednakosti temelji se ideja mjerenja (in)konzistencije procjena. Naime, što je veća inkonzistencija, veća je razlika $\lambda_{\max} - n$, a time i prosječna vrijednost preostalih svojstvenih vrijednosti. Ta prosječna vrijednost uzima se kao mjera (in)konzistencije i zove se *indeks konzistencije*:

$$CI = \frac{|\lambda_2 + \dots + \lambda_n|}{n-1} = \frac{\lambda_{\max} - n}{n-1}$$

Budući da nije isto postiže li se jednaka vrijednost indeksa konzistencije na manjem ili većem broju procjena, taj indeks se povezuje s redom matrice A na taj način što se stohastički konstruiraju matrice procjena različitih redova i za takve matrice se računa *slučajni indeks*

$RI = \frac{1}{N} \sum_{i=1}^N CI(i)$ i izrađena je tablica vrijednosti za ovaj indeks. Omjer ova dva indeksa zove se

$$\text{omjer konzistencije i označava } CR = \frac{CI}{RI} = \frac{\lambda_{\max} - n}{RI(n-1)}$$

Aproksimativno računanje najveće svojstvene vrijednosti i najvećeg svojstvenog vektora matrice procjena A:

Jedan način približnog računanja svojstvene vrijednosti i svojstvenog vektora (*metoda zbroja*) temelji se na slijedećim povezanim jednakostima:

$$Aw = nw \Rightarrow \sum_j a_{ij} w_j = n w_i \text{ otuda je } w_i = \frac{1}{n} \sum_j a_{ij} w_j \text{ . Zbog } \sum_i a_{ij} = \frac{w_1 + \dots + w_n}{w_j} \text{ i uvjeta}$$

$$\text{normalizacije težina (prioriteta) } \sum_i w_i = 1 \text{ proizlazi } w_j = \frac{1}{\sum_i a_{ij}} \text{ i konačno } w_i = \frac{1}{n} \sum_j \frac{a_{ij}}{\sum_i a_{ij}} \text{ .}$$

Da bi se na temelju ovog izračunale težine w_i primjenjuje se postupak od tri koraka:

Korak 1: Izračunaju se sume stupaca.

Korak 2: Matrica A se normalizira dijeljenjem svih elemenata pojedinog stupca sumom tog stupca.

Korak 3: Težine se izračunaju kao prosječne vrijednosti elemenata redaka normalizirane matrice A .

Kako se može izračunati približna vrijednost najveće svojstvene vrijednosti λ_{\max} ?

Zbog $Aw = \lambda_{\max} w$ za svaku komponentu w_i svojstvenog vektora w vrijedi $\lambda_{\max} = \frac{1}{w_i} \sum_j a_{ij} w_j$.

Otuda proizlazi jednostavan algoritam za računanje približne vrijednosti od λ_{\max} :

Korak 1: Stupci matrice A pomnože se s pripadnim težinama

Korak 2: Izračunaju se sume redova tako dobivene matrice

Korak 3: Sume redova podijele se redom s pripadnim težinama

Korak 4: Najveća svojstvena vrijednost λ_{\max} izračuna se kao prosječna vrijednost veličina izračunatih u koraku 3.

Ovo nije jedini način da se približno izračunaju težine i najveća svojstvena vrijednost. Postoji još i *metoda korijena* i *metoda potenciranja*. Ove metode prikazuju se bez posebnog objašnjenja njihove teorijske utemeljenosti:

Metoda korijena

Korak 1: Za svaki red izračuna se produkt svih njegovih elemenata $M_i = \prod_j a_{ij}$

Korak 2: Izračunaju se vrijednosti $\alpha_i = \sqrt[n]{M_i}$

Korak 3: Težine se izračunaju kao $w_i = \frac{\alpha_i}{\sum_j \alpha_j}$

Najveća svojstvena vrijednost računa se na temelju ovako izračunatih težina kao kod metode zbroja.

Metoda potencija

Zbog toga što općenito vrijedi $W = \frac{1}{c} \lim_{k \rightarrow \infty} \frac{A^k e}{e^T A^k e}$ vektor težina i najveća svojstvena vrijednost mogu se izračunati i na slijedeći način:

Korak 1: Neka je $X^{(0)}$ proizvoljan vektor stupac iz matrice A i $m_0 = \|X^{(0)}\|_{\infty}$. Iterativni postupak počinjemo s $Y^{(0)} = X^{(0)} / m_0$.

Korak 2: $X^{(k+1)} = AY^{(k)}$, $m_{k+1} = \|X^{(k+1)}\|_{\infty}$, $Y^{(k+1)} = X^{(k+1)} / m_{k+1}$

Iterativni postupak provodi se tako dugo dok se za zadani ε ne ispuni uvjet $|m_{k+1} - m_k| < \varepsilon$. Tada se za vektor težina uzima $W = Y^{(k+1)} / \|Y^{(k+1)}\|$ a za najveću svojstvenu vrijednost $\lambda_{\max} = m_{k+1}$.

5.1.2.2. Konzistentnost donositelja odluke

AHP metoda spada u primjenjive metode i iz razloga što ima sposobnost identificirati i analizirati nekonzistentnost donositelja odluke u procesu uspoređivanja elemenata hijerarhije. Čovjek je rijetko konzistentan pri procjenjivanju vrijednosti ili odnosa kvalitativnih elemenata u hijerarhiji, a uzroci nekonzistentnosti mogu biti različiti (Forman, 2007.):

- pomanjkanje koncentracije – uslijed umora ili nezainteresiranosti procjenitelja,
- administrativna greška – najčešći razlog nekonzistentnosti je unos pogrešne (inverzne) vrijednosti pojedinog težinskog faktora; administrativne greške često prođu neprimjećeno u mnogim računalnim analizama,
- nepostojanje konzistentnosti u stvarnom problemu koji treba modelirati, jer je stvarni svijet često nekonzistentan (npr. u športu ne vrijedi tranzitivnost: ekipa A pobijedi ekipu B, ekipa B ekipu C, no ekipa C pobjeđuje ekipu A),
- neadekvatna struktura modela – u idealnoj hijerarhijskoj strukturi faktori su na svakom nivou usporedivi u okvirima postojeće skale (1-9); previsoka nekonzistentnost može nastati jer su nužna ekstremna određivanja prioriteta u parovima (npr. alternativa A je u odnosu na neki kriterij 7 puta vrednija od alternative B, a alternativa B čak 9 puta vrednija od alternative C, što znači da je alternativa A 63 puta vrednija od alternative C, što je daleko iznad maksimalne vrijednosti korištene Saatyve skale),
- nedostatak informacija – pomanjkanjem pravih informacija (zbog osobnog propusta ili namjernog izbjegavanja troškova za prikupljanje potrebnih podataka), moguća je nedosljednost u određivanju prioriteta pri usporedbi u parovima.

Nekonzistentnost procjena moguće je najjednostavnije objasniti pomoću sljedećeg primjera (Hunjak, 2004. (knjiga Cerić)). Pretpostavimo da imamo tri kamena A, B i C za koje znamo da ukupno teže 22 kg, ali nam nisu poznate njihove pojedinačne težine. Mi znamo njihove omjere težina A:B=2:1 (kamen A je dvostruko teži od kamena B) i A:C=3:1 (kamen A je trostruko teži

od kamena C). Iz ovoga proizlazi diobeni omjer težina 6:3:2 iz kojeg lako izračunamo da su tražene težine kamena redom 12, 6 i 4 kg. Umjesto kamena možemo zamisliti da međusobno uspoređujemo kriterije te im izračunavamo težine kao mjeru njihove važnosti. Isto tako možemo uspoređivati alternative po prioritetima kako bismo odredili prioritet svake od njih. Problemi nastaju zbog toga što naše procjene obično nisu konzistentne. U primjeru s kamenjem, na temelju poznatih omjera težina proizlazi da je omjer težina drugog i trećeg kamena B:C=3:2. U tom slučaju kaže se da su omjeri A:B, A:C i B:C konzistentni. Međutim, kad bi tražili od nekoga da uzme te kamene u ruke i da procjeni omjere njihovih težina, malo je vjerojatno da bi te procjene bile konzistentne. U tom slučaju kod računanja težina kamena ne bi mogli primijeniti pravila iz računa diobe. Pretpostavimo npr. da smo dobili procijenjenu vrijednost omjera B:C=4:3. Taj omjer zajedno s omjerom A:B=2:1 daje diobeni omjer 8:4:3. Ako bi pak omjeru B:C=4:3 pridružili procijenjeni omjer A:C=3:1, dobili bi diobeni omjer 9:4:3, dakle različit od 8:4:3. Dakle, ukoliko se od donositelja odluke traže procjene težina kriterija ili prioriteta alternativa u parovima, u realnim problemima odlučivanja, te procjene će najčešće biti nekonzistentne.

Stoga, AHP metoda ima veliku prednost što omogućuje praćenje konzistentnosti procjena u svakom trenutku postupka uspoređivanja elemenata u parovima. Uz pomoć indeksa konzistencije $CI = (\lambda_{max} - n) / (n - 1)$ izračunava se omjer konzistencije $CR = CI / RI$, gdje je RI slučajni indeks, odnosno indeks konzistencije (primjenjuje se samo ako je $n \geq 3$) za matrice reda n slučajno generiranih usporedbi u parovima (Tablica 5-5.).

Tablica 5-5. Vrijednosti RI slučajnih indeksa (Saaty, 1980.)

<i>n</i>	1	2	3	4	5	6	7	8	9	10
<i>RI</i>	0	0	0,52	0,89	1,11	1,25	1,35	1,40	1,45	1,49

Ako za matricu A vrijedi $CR \leq 0,10$, procjene relativnih važnosti kriterija (prioriteta alternativa) smatraju se prihvatljivima. U suprotnom treba istražiti razloge zbog kojih je nekonzistentnost procjena neprihvatljivo visoka.

5.1.3. Prednosti i nedostaci AHP metode

Na prednosti Analitičkog hijerarhijskog procesa kao metode za podršku odlučivanju ukazivali su brojni znanstvenici i praktičari (Saaty, 1977., 1980., 1991., 2006., Schoemaker & Waid, Narasimhan, 1983., Harker & Vargas, 1987., Alphonse, 1997., Karlsson, 1998., Triantaphyllou, 2000., Sunn, 2001., Hamalainen, 2004.). U usporedbi s drugim metodama, AHP metoda je često pokazivala bolje uporabne karakteristike, što je od velike važnosti, ukoliko se ima u vidu još uvijek prisutni animozitet donositelja odluka prema sofisticiranim metodama odlučivanja. Nadalje, AHP metoda ima i određene nedostatke koji nisu direktno vezani za metodološki niti matematički temelj metode, ali se navode kao njena ograničenja.

Od značajnijih prednosti AHP metode izdvajamo sljedeće (Saaty, 1977., 1980., 1991., 2006., Schoemaker & Waid, Narasimhan, 1983., Harker & Vargas, 1987., Alphonse, 1997., Karlsson, 1998., Triantaphyllou, 2000., Sunn, 2001., Hamalainen, 2004.):

- AHP strukturira problem odlučivanja i uspješno simulira proces donošenja odluka od definiranja cilja, kriterija i alternativa, do uspoređivanja kriterija i alternativa u parovima i dobivanja rezultata, odnosno utvrđivanja prioriteta svih alternativa u odnosu na postavljeni cilj. Ona dekomponira realni proces odlučivanja tako što razlaže problem u hijerarhiju elemenata tog procesa te poštujući činjenicu da donositelj odluka na mentalnom planu uglavnom ne razdvaja proces procjenjivanja kriterija od alternativa, omogućava kontrolu konzistentnosti procjena, vodeći računa o cjelini problema i funkcionalnim interakcijama kriterija i alternativa.
- AHP integrira kvalitativne i kvantitativne faktore u odlučivanju. Praksa do uvođenja AHP-a ignorirala je važnost kvalitativnih faktora u odlučivanju, ne uzimajući u obzir da su svi ljudski problemi kombinacija psiholoških i fizičkih aktivnosti, kvalitativnih i kvantitativnih elemenata. AHP je teorija relativnog mjerenja koja koristi apsolutnu skalu za mjerenje kvalitativnih i kvantitativnih kriterija koji su homogeni i temeljeni na procjenama eksperata.
- AHP uspješno identificira i ukazuje na nekonzistentnost donositelja odluka praćenjem nekonzistentnosti u procjenama tijekom cijelog postupka, izračunavanjem indeksa i omjera konzistencije. U tijeku procjenjivanja, korisnik ima osjećaj da programski alat

ispravno prati njegov proces razmišljanja i da mu pravovremeno ukazuje da li je procjenjivanje konzistentno. Ovo je važno kada se uzme u obzir da su donositelji odluka rijetko kada konzistentni u svom procjenjivanju u odnosu na kvalitativne aspekte problema. Kod kombinacija kvalitativnih i kvantitativnih kriterija, mogućnosti za pojavu nekonzistentnosti su najizraženije.







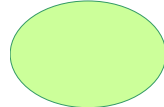


- Redundantnost uspoređivanja u parovima dovodi do toga da je AHP metoda manje osjetljiva na greške u procjenjivanju.
- Kada se koristi pri grupnom donošenju odluka, AHP metoda značajno poboljšava komunikaciju među članovima grupe. Ukoliko se provodi diskusija, grupa se treba usuglasiti oko svake zajedničke procjene koja će se unijeti u matricu. AHP pomaže u strukturiranju diskusije i postizanju konsenzusa. Ukoliko govorimo o grupnom odlučivanju u kojem svaka osoba ima mogućnost unosa procjena, izbjegava se mogućnost tzv. «skupnog mišljenja», jedinstvenog mišljenja svih članova skupine do kojeg dolazi zbog velikog pritiska na sudionike koji imaju drugačije mišljenje. Svaki sudionik sudjeluje u zajedničkoj diskusiji, ali na njenom završetku individualno unosi svoju procjenu. Time se postiže bolje razumijevanje, a u konačnom ishodu članovi grupe imaju više povjerenja u izabranu alternativu.
- Odlučivanje AHP metodom povećava znanje o problemu i snažno i brzo motivira donositelje odluke. Procesom odlučivanja dolazi se do približnog rješenja problema i to obično većom brzinom nego na većini sastanaka te s manjim troškovima procesa donošenja odluke. Tako dobiveni rezultati mogu se koristiti i kao ulazni podaci za projekt ili studiju izvodljivosti, odnosno za kompleksniju odluku.
- Rezultati odlučivanja AHP metodom ne sadrže samo rang alternativa već i informacije o težinskim koeficijentima kriterija u odnosu na cilj i podkriterija u odnosu na kriterije.
- AHP omogućuje donositelju odluka analizu osjetljivosti rezultata pomoću koje se provjerava stabilnost dobivenih rezultata na način da se simulira odnos između težina kriterija i prioriteta alternativa.
- Postojanje kvalitetnih programskih alata koji podržavaju AHP metodu. Najčešće korišten alat je *Expert Choice* (Expert Choice, 2000.) koji ima mnoge prednosti kao što jednostavnost modeliranja, sučelje prilagođeno prosječnom korisniku računala, mogućnost korigiranja procjena od strane korisnika i dr. Alat *SuperDecisions*

(SuperDecisions, 2006.) također podupire primjenu AHP metode, besplatan je i razvijen kako bi podržao korištenje AHP i ANP metode u akademske svrhe. Alat *DecisionLens* (DecisionLens, 2007.) razvijen je u komercijalne svrhe kako bi omogućio primjenu AHP metode u poslovnim organizacijama. Gotovo sve napoznatije američke kompanije koriste *DecisionLens* u odlučivanju, planiranju, alokaciji resursa i dr. Osnovna karakteristika koja ga razlikuje od drugih alata je jednostavnost sučelja i primjene.

AHP metoda ima i određena ograničenja s kojima se korisnici mogu susresti prilikom njene primjene, a mnogi znanstvenici se bave načinima za njihovo otklanjanje. Izdvajamo neka od ograničenja AHP-a koja se češće navode u literaturi (Belton, 1986., Schoner & Wedley, 1989., Dyer, 1990., Lootsma, 1991., Schoner, Wedley, Choo, 1993., Salo & Hamalainen, 1999.):

- nedovoljno velika skala (Saatyeva skala relativne važnosti) za uspoređivanje elemenata u parovima vezano uz neke probleme odlučivanja,
- velik broj potrebnih komparacija u parovima kod većine problema,
- postizanje prihvatljivog omjera konzistencije je često vrlo teško,
- nisu dozvoljene neusporedive alternative.

Prvi i posljednji navedeni nedostatak se najčešće spominju kao najveći nedostaci AHP metode. U nastavku se navodi primjer kako je moguće proširiti skalu relativnih važnosti s 9 intenziteta i uspoređivati možda na prvi pogled neusporedive alternative (Saaty, Katz predavanja, 2008.). Potrebno je klasterirati objekte u grupe i koristiti najveći element u prvoj grupi kao najmanji u sljedećoj grupi, odnosno koristiti taj element kao osnovicu za povezivanje dvije grupe. Na taj način se elementi unutar jedne grupe mogu upoređivati sa skalom od 1-9 i mogu se generirati njihovi prioriteti, a zatim se prioriteti dijele s prioritetoj najmanjeg elementa u toj grupi i množe s prioritetoj elementa iz prethodne grupe koji je služio kao osnovica povezivanja grupa (slika 5-2.). Opisanim postupkom je moguće uspoređivati i mjeriti i potpuno različite elemente, npr. kao na slici 5-2., voće potpuno različitih veličina, trešnju i lubenicu (Saaty, Katz predavanja, 2008., Saaty, 2005c).

	.07		.28		.65
<i>Mala rajčica</i>		<i>Mala zelena rajčica</i>		<i>Limeta</i>	
	.08		.22		.70
<i>Limeta</i> $\frac{.08}{.08} = 1$ $.65 \times 1 = .65$		<i>Grejp</i> $\frac{.22}{.08} = 2.75$ $.65 \times 2.75 = 1.79$		<i>Dinja</i> $\frac{.70}{.08} = 8.75$ $.65 \times 8.75 = 5.69$	
	.10		.30		.60
<i>Dinja</i> $\frac{.10}{.10} = 1$ $5.69 \times 1 = 5.69$		<i>Lubenica</i> $\frac{.30}{.10} = 3$ $5.69 \times 3 = 17.07$		<i>“Duguljasta” lubenica</i> $\frac{.60}{.10} = 6$ $5.69 \times 6 = 34.14$	

Slika 5-2. Klasteriranje pri uspoređivanju nehomogenih elemenata

5.1.4. Pregled primjena AHP metode

AHP metoda ima vrlo širok spektar primjena te je korištena u rješavanju problema u raznim područjima kao što su menadžment, industrija, inženjerstvo, politika, obrazovanje, šport.

Vaidya i Kumar objavili su 2006. godine pregled literature (Vaidya & Kumar, 2006.) ukupno 150 publikacija objavljenih u uglednim međunarodnim znanstvenim časopisima u razdoblju od 1983. – 2003. godine, u kojima je AHP metoda primijenjena u rješavanju određenog tipa problema. Pregled publikacija je analiziran prema tematici primjene i prema području primjene. Pregled literature prema broju publikacija te prema tematici i području primjene nalazi se u tablici 5-6., a grafički prikaz na slici 5-3. i 5-4.

Prema tematici primjene, AHP je najčešće primjenjivana u rješavanju problema odabira (32 publikacije) te evaluacije (26 publikacija). AHP metoda je primjenjena manji broj puta u predviđanjima, odnosno objavljene su samo 4 publikacije u kojima AHP služi u rješavanju problema predviđanja (tablica 5-6., slika 5-3.). Analizirajući područje primjene, AHP je najčešće primjenjivana u rješavanju osobnih problema (26 publikacija) te u domeni inženjerstva (26

publikacija) (tablica 5-6., slika 5-4.). Relativno mali broj primjena ima u politici (6 publikacija) i obrazovanju (11 publikacija) (tablica 5-6., slika 5-4.). Gledajući vremensku distribuciju objava, najveći broj publikacija, ukupno 58% objavljeno je u razdoblju od 1998. – 2003. godine, a samo 18 publikacija je objavljeno prije 1990. godine (slika 5-5.).


Analitički hijerarhijski proces je često primjenjivan u integraciji s nekim drugim metodama, pa je pregled literature u kojoj je AHP metoda primjenjena u integraciji s nekom drugom metodom, u razdoblju od 1997. – 2006. godine, napravio i objavio Ho 2008. godine (Ho, 2008.) (tablica 5-6., slika 5-6.). Najveći broj publikacija je usmjeren na integraciju AHP-a i matematičkog programiranja (33 publikacije), te na primjenu integracije AHP-a i QFD-a (*Quality Function Deployment*) u rješavanju određenog problema (16 publikacija). Grafički prikaz primjene integracije AHP-a i drugih metoda u rješavanju određenih problema nalazi se na slici 5-6.

Napravljeno je i pretraživanje baze SCI-EXPANDED (Science Citation Index Expanded, 2008.) (pretraživanje po ključnim riječima AHP i/ili Analytic Hierarchy Process) kako bi se utvrdio broj radova koji pokrivaju temu AHP-a, a koje su objavili autori iz Hrvatske u priznatim međunarodnim znanstvenim časopisima. Ukupno je pretraživanjem pronađeno četiri publikacije koje su objavili profesori sa Sveučilišta u Zagrebu i Sveučilišta u Splitu u časopisima: *Central European Journal of Operations Reserach*, *European Journal of Operational Reserach*, *International Journal of Production Economics* i *Ekologia-Bratislava*. Rad «*Prioritization of e-learning forms: a multicriteria methodology*» (Begicevic, Divjak & Hunjak, 2007.) objavljen u *Central European Journal of Operational Reserach*, objavila je autorica ove doktorske disertacije u koautorstvu s mentorom prof.dr.sc. Hunjakom i sumentoricom prof.dr.sc. Divjak, te su u članku prezentirani neki od rezultata dobiveni istraživanjem u okviru ove doktorske disertacije. Plazibat i Babic (Plazibat & Babic, 1998.) su u svojem radu objavljenom u časopisu *International Journal of Production Economics* rangirali poduzeća na temelju višekriterijske analize primjenivši kombinaciju AHP metode te metode PROMETHEE. Jure Margeta je u koautorstvu sa stranim autorima Fontaneom i Koom objavio rad u kojem je AHP metoda primijenjena u rješavanju problema operativnog planiranja akumulacijskog sustava (Ko, Fontane & Margeta, 1994.). Spanjol, Segotic, Jazbec i Hitrec (Spanjol, Segotic, Jazbec & Hitrec, 2003.) u svojem su radu primijenili AHP model kao pomoć u analizi promjena u trajanju požara i veličini izgorjetih područja na otoku Rabu i Korčuli, koji imaju jednaku vegetaciju i klimatske uvjete.


Ova doktorska disertacija se bavi primjenom AHP-a u području obrazovanja gdje je relativno mali broj primjena do sada. S druge strane, opisana je integracija AHP-a s metodom faktorske analize što također predstavlja određenu inovaciju.

Tablica 5-6. Pregled primjena AHP-a


Pregled primjena AHP-a	Izvori
<p>Primjena AHP metode – pregled literature u 3 osnovne grupe:</p> <p>Prema tematici primjene:</p> <ul style="list-style-type: none"> - problem odabira (32 publikacije) - problem evaluacije (26 publikacija) - odlučivanje (21 publikacija) - određivanje prioriteta i rangiranje (20 publikacija) - problem alokacije (10 publikacija) - planiranje i razvoj (10 publikacija) - benefit-cost analiza (7 publikacija) - predviđanje (4 publikacije) <p>Prema specifičnoj primjeni:</p> <ul style="list-style-type: none"> - medicina i vezana područja (5 publikacija) <p>Integracija AHP-a s drugim metodom:</p> <ul style="list-style-type: none"> - QFD (<i>Quality Function Deployment</i>) (7 publikacija) <p>Klasifikacija je napravljena i prema području primjene:</p> <ul style="list-style-type: none"> - osobna (26 publikacija) - inženjerstvo (26 publikacija) - društvena (23 publikacije) - proizvodnja (18 publikacija) - industrija (15 publikacija) - vlada (13 publikacija) - ostalo (sport, menadžment ...) (12 publikacija) - obrazovanje (11 publikacija) - politička (6 publikacija) 	<p>Vaidya & Kumar, 2006. (Vaidya & Kumar, 2006.) – PREGLED LITERATURE (150 publikacija), analizirane publikacije (članci u međunarodnim časopisima) u kojima je primjenjena AHP metoda, u razdoblju od: 1983 - 2003</p>
<p>Integracija AHP metode s drugim metodama i njihova primjena – pregled literature</p> <ul style="list-style-type: none"> - primjene integracije AHP-a i matematičkog programiranja (33 publikacije) - primjene integracije AHP-a i QFD-a (<i>Quality Function Deployment</i>) (16 publikacija) - primjene integracije AHP-a i meta heuristike (8 publikacija) - primjene integracije AHP-a i SWOT analize (5 publikacija) - primjene integracije AHP-a i DEA (<i>Data Envelopment Analysis</i>) (4 publikacije) 	<p>Ho, 2008. (Ho, 2008.) – PREGLED LITERATURE (66 publikacija), analizirani članci objavljeni u međunarodnim časopisima u kojima je primjenjena AHP metoda integrirana s nekom drugom metodom, u razdoblju od: 1997 – 2006</p>




Slika 5-3. Tematska distribucija AHP aplikacija (prilagođeno prema Vaidya & Kumar, 2006.)



Slika 5-4. Područja primjene AHP-a (prilagođeno prema Vaidya & Kumar, 2006.)



Slika 5-5. Vremenska distribucija AHP publikacija (prilagođeno prema Vaidya & Kumar, 2006.)



Slika 5-6. Integracija AHP metode s drugim metodama prema broju publikacija (prilagođeno prema Ho, 2008.)

5.2. AHP model za donošenje odluke o uvođenju e-učenja u visoko školstvo

AHP model za višekriterijsko odlučivanje o obliku uvođenja e-učenja na razini određene katedre i/ili kolegija, razvijen je na temelju kriterija i podkriterija reduciranih u postupku faktorske analize. Detaljno objašnjenje kriterija i podkriterija te alternativa, nalazi se u poglavlju 5.2.1. Testiranje modela provedeno je grupnim odlučivanjem o obliku uvođenja e-učenja na kolegij Matematika, na Katedri za kvantitativne metode, na Fakultetu organizacije i informatike. U razvoju i testiranju modela koristio se alat *TeamEC2000* (Expert Choice, 2000.).

Razvojem i testiranjem AHP modela, potvrđena je druga hipoteza koja glasi:

H2: Na temelju definiranih kriterija, moguće je razviti AHP model te grupnim odlučivanjem metodom analitičkog hijerarhijskog procesa donijeti odluku o obliku uvođenja e-učenja na razini katedre i kolegija.

Razvijeni AHP model omogućava sudionicima grupnog odlučivanja da procjene koji od oblika e-učenja, s obzirom na definirane kriterije i podkriterije odlučivanja, donosi veće prednosti u učenju, podučavanju, ali i u ostvarenju ostalih elemenata misije sveučilišta. AHP model je uspješno testiran na Fakultetu organizacije i informatike, na Katedri za kvantitativne metode, za kolegij Matematika, provedeno je grupno odlučivanje, integriranje različitih aspekata mišljenja te prezentiranje jedinstvenog zajedničkog rješenja donositelja odluke.

Postupak razvoja hijerarhijskog modela problema odlučivanja te testiranje modela i rezultati grupnog odlučivanja AHP metodom uz potporu alata *TeamEC2000*, prikazani su u poglavlju 5.2.

5.2.1. Razvoj hijerarhijskog modela problema odlučivanja

U postupku razvoja hijerarhijskog modela problema odlučivanja primjenjena je kombinirana metoda istraživanja koja je obuhvatila sljedeće metode (detaljnije u poglavlju 4.):

- anketu kojom su prikupljeni podaci od eksperata,
- deskriptivnu statistiku za obradu prikupljenih podataka,
- klasteriranje za analizu podataka i
- faktorsku analizu za reduciranje skupa podataka prikupljenih anketom te definiranje kriterija potrebnih za razvoj AHP modela.

Primjenom kombinirane metode integrirano je znanje eksperata i razvijen je složeni model za višekriterijsko odlučivanje o strateškom uvođenju e-učenja u visoko školstvo na razini katedre i/ili kolegija. Model ima svoju primjenu u strukturiranju problema i procesu odlučivanja, a uz pomoć takvog modela donositelji odluke se mogu lakše fokusirati na strateške vrijednosti dobivenih rješenja i koristiti ih za povećanje učinkovitosti implementacije i razvoj sustava u planiranom smjeru. Model i postupak testiranja modela, detaljno su opisani u poglavlju 5.2.2. i 5.2.3. U nastavku se nalaze objašnjenja alternativa i podkriterija u modelu.

U tabeli 5-7. opisana su četiri oblika e-učenja: klasična nastava, nastava uz pomoć ICT, hibridna ili mješovita nastava i online obrazovanje (Zemsky, 2004.). U AHP modelu za odlučivanje o strateškom uvođenju e-učenja u visoko školstvo na razini katedre i/ili kolegija korištene su sve četiri alternative.

Tablica 5-7. Opis alternativa (karakteristike oblika e-učenja) (prilagođeno prema Zemsky, 2004.)

Oblik	Opis	Tehnologije
Klasična nastava (f2f, licem u lice)	nastava (najčešće predavačka) u učionici	<ul style="list-style-type: none"> ▪ Ne koriste se, osim npr. tekst procesor (<i>Word</i>) za pripremanje nastave
Nastava uz pomoć ICT	tehnologija se koristi uglavnom zato da bi se poboljšala klasična nastava	<ul style="list-style-type: none"> ▪ Prezentacije (<i>PowerPoint</i>) ▪ Multimedijски CD-ROM-ovi ▪ Web sjedišta za kolegije s hipermedijskim sadržajima za učenje (<i>courseware</i>) ▪ Programi za testiranje (kvizovi za samoprovjeru znanja i provjere znanja) ▪ E-mail i mailing liste ▪ Forum
Hibridna ili mješovita nastava	kombinacija klasične nastave u učionici i nastave uz pomoć tehnologija	<ul style="list-style-type: none"> ▪ LMS (<i>Learning Management Systems</i>) - sustavi za upravljanje učenjem ▪ CBT/WBT (<i>Computer/Web Based Training</i>) ▪ Videokonferencije
Online obrazovanje	učenje i poučavanje odvija se isključivo uz pomoć tehnologije, nema f2f nastave	<ul style="list-style-type: none"> ▪ Predmeti (kolegiji, tečajevi) koji se dostavljaju putem Interneta (kao Web sjedišta ili pomoću LMS-a) ▪ Videokonferencije

U nastavku su detaljno opisani podkriteriji razvijenog hijerarhijskog AHP modela odlučivanja o strateškom uvođenju e-učenja u visoko školstvo na razini katedre i/ili kolegija.

Kriterij ORGANIZACIJSKA I STRATEŠKA SPREMNOST FAKULTETA

Razvojna strategija fakulteta

Uvođenje e-učenja na razini pojedinog fakulteta ne može uspjeti bez podrške i motivacije samog fakulteta. Fakulteti trebaju kreirati strategiju e-učenja, izraditi strateške odrednice u razvojnim planovima fakulteta za uvođenje e-učenja, osigurati izvore financiranja za uvođenje e-učenja, uspostaviti infrastrukturu za implementaciju te motivirati i omogućiti adekvatno usavršavanje pomoćnog osoblja i nastavnika za korištenje sustava podrške e-učenju.

Sveučilišni razvojni okvir - razvojna strategija obrazovanja na sveučilištu

Uvođenje e-učenja na sveučilišta i pojedine fakultete mora imati podršku od strane sveučilišta. Sveučilišta trebaju unutar svog razvojnog okvira, definirati jasan cilj poboljšanja kvalitete obrazovanja primjenom tehnologija e-učenja. Nakon toga je potrebno na razini sveučilišta postići dogovor o svrsi i strategiji primjene e-učenja, te uspostaviti potrebne formalno-pravne okvire za vrednovanje i sveobuhvatnu primjenu e-učenja. Potrebno je osmisliti i staviti u funkciju sustav potpore sveučilišnim nastavnicima, kako bi primjena informacijskih i komunikacijskih tehnologija, a posebno tehnologija e-učenja, bila što jednostavnija i učinkovitija.

Financijska spremnost sveučilišta i fakulteta

Na razini sveučilišta i fakulteta javlja se pitanje financijske spremnosti za uvođenje e-učenja. Prvi korak je istraživanje troškova i prednosti koje donosi uvođenje e-učenja na određeno sveučilište/fakultet. Ključna je izrada financijskog plana uvođenja e-učenja, definiranje osnovnih kanala i izvora financiranja, definiranje dodatnih izvora financiranja i potencijalnih izvora zarade. Potrebno je procijeniti opravdanost investicije uvođenja e-učenja.

Kriterij RASPOLOŽIVOST TEMELJNE ICT INFRASTRUKTURE

Mrežna infrastruktura

Mrežna infrastruktura *on campus* i *off campus* izuzetno je bitna za e-učenje. Trenutno je postojeća mrežna infrastruktura zasnovana na tehnologiji gigabitnog Ethernet, ravnopravna s drugim europskim i svjetskim akademskim mrežama, ali u području pristupnih mreža situacija je

zabrinjavajuće udaljena od akademskih standarda. Neke od prednosti korištenja Ethernet tehnologije su niska cijena, jednostavnost mreže, velika skalabilnost, velika učinkovitost, velike brzine prijenosa podataka, sigurnost, mogućnosti uspostave virtualnih privatnih mreža (*Virtual Private Network – VPN*) i uspostave usluge prijenosa podataka u zajamčenoj kvaliteti (*Quality of Service – QoS*). Nastavnici i studenti u kampusu (*on campus*) nemaju problema s brzinom pristupa i ostalim karakteristikama postojeće mrežne infrastrukture. Izvršeno je i spajanje studentskih domova na mrežu i uspostava lokalnih računalnih mreža po studentskim sobama. Problem je sa studentima van kampusa (*off campus*) koji pristupaju mreži od kuće. Jedna od mogućnosti je ADSL mjesečni studentski pristup. Dostupnost DSL tehnologije raste, ali cijena je još uvijek previsoka za kućni budžet.

Računalna opremljenost nastavnika i studenata

Računalna opremljenost nastavnika i studenata nužna je za postizanje kvalitetnog obrazovanja, a naročito za primjenu e-učenja. Nastavnici i studenti trebaju biti dobro opremljeni za izvođenje i sudjelovanje u procesu učenja i podučavanja. Broj nastavnika i studenata koji raspolažu vlastitim stolnim računalima i/ili prijenosnim računalima te drugim uređajima i komponentama potrebnim za e-učenje treba bilježiti stalan porast.

Na studentskoj anketi provedenoj na FOI-u u lipnju 2006 godine, studenti su ocijenili da 76% nastavnika upotrebljava nastavna pomagala i suvremene tehnologije umjereno (ocjena 3 - 21%) ili intenzivno (ocjena 4 i 5 - 55%).

Integralni sustav upravljanja procesom obrazovanja (MLEs)

Integralni sustav upravljanja procesom obrazovanja (*Managed learning environments (MLEs)*) pruža kompletnu podršku nastavnicima i studentima: omogućuje pristup informacijama, komuniciranje s fakultetom i unutar fakulteta, zahtjeva i omogućuje razvoj i implementaciju virtualnog edukacijskog okružja (*CMS, LMS, LCMS...*) za internu komunikaciju, omogućuje vođenje diskusija, ocjenjivanje i vrednovanje, provedbu politike podučavanja i učenja te politike osiguranja kvalitete. Sustav upravljanja procesom obrazovanja treba omogućiti i administriranje tečajeva, registraciju studenata, praćenje aktivnosti i zalaganja studenata, ocjenjivanje studenata i administriranje lista prolaza.

Tehnička opremljenost predavaonica i učionica na fakultetu

Bez dobre tehničke opremljenosti predavaonica i učionica na fakultetima ne mogu se primijeniti napredne metode učenja i podučavanja, pa tako niti e-učenje. Tehnička opremljenost predavaonica i učionica na fakultetima obuhvaća dobru opremljenost s uređajima i komponentama, ne samo računalima, monitorima, štampačima, prezentacijskom i drugom opremom već omogućavanje studentima i nastavnicima da koriste interaktivne tehnologije, npr. *e-notebook* ili *e-paper* te im osigurati opremu za što jednostavniji pristup virtualnim resursima uključujući i mogućnost bežičnog web pristupa.

Kriterij LJUDSKI RESURSI

Specijalizirani centar potpore e-učenju

Specijalizirani centar potpore e-učenju treba osmisliti i uspostaviti kao trajno održiv centar koji služi kao multidisciplinarni sustav potpore sveučilišnim nastavnicima i studentima pri uvođenju i uporabi tehnologija e-učenja. Centar potpore e-učenju treba osigurati da se nastavnici mogu koncentrirati na sadržaj obrazovanja, a da mogućnosti koje nudi tehnologija budu jednostavan alat za ostvarivanje obrazovnih ciljeva. Svako sveučilište u Hrvatskoj će osmisliti svoj organizacijski model uspostave Centra potpore e-učenju. Sveučilište u Zagrebu će najvjerojatnije zbog svoje veličine i diverzifikacije izabrati decentralizirani model s centralnom jedinicom na sveučilišnoj razini. Centar bi trebao uključivati: osoblje za tehničku potporu e-učenju, osoblje za metodičku potporu e-učenju te osoblje za grafičko oblikovanje, animaciju i video. Kompetencije kojima bi trebao vladati su: metodologija i pedagogija, komunikacijske vještine, instruktorski dizajn, grafički dizajn, poznavanje alata za e-učenje i ICT alata, testiranje i evaluacija, projektni menadžment, projektna koordinacija, upravljanje i vođenje timova i dr.

Raspoloživost pomoćnog osoblja za tehničku potporu e-učenju

Raspoloživost pomoćnog osoblja za tehničku potporu e-učenju nužan je preduvjet za uvođenje e-učenja na fakultete. Potrebno je pronaći način da pomoćno osoblje za tehničku potporu e-učenju počne djelovati na razini fakulteta i pružati tehničku potporu nastavnicima u savladavanju tehnologije e-učenja.

Raspoloživost pomoćnog osoblja za metodičku potporu e-učenju

Raspoloživost pomoćnog osoblja za metodičku potporu e-učenju također je jedan od važnih preduvjeta za uvođenje e-učenja na visokoškolske institucije. Metodika obrazovanja se razlikuje kod

klasične nastave u predavaonici i kod e-učenja. Pogrešna metodika može kod e-učenja dovesti do situacije u kojoj se pedagoški aspekti obrazovanja mogu izgubiti. S druge strane, e-učenje može riješiti problem masovnog studiranja i omogućiti da se vrijeme koje nastavnik i student imaju na raspolaganju iskoristi za najkvalitetniju komunikaciju, raspravu, prijenos znanja te pregled najvažnijih nastavnih materijala.

Raspoloživost pomoćnog osoblja za grafičko oblikovanje, animaciju i video

Raspoloživost pomoćnog osoblja za grafičko oblikovanje, animaciju i video je ključno pri proizvodnji video i audio materijala te ostalih multimedijalnih sadržaja koji se u velikoj mjeri koriste u e-učenju. Pomoćno osoblje rješava probleme pribave materijala, korištenja uređaja kojim se konkretan materijal unosi u računalo, obrade materijala i izrade multimedijalnih elemenata. Izvedbeni postupak za proizvodnju multimedijalnih sadržaja sastoji se od sljedećih koraka: pripreme materijala, obrade materijala, izrade materijala i kompresije materijala.

Sustav kontinuiranog usavršavanja nastavnog osoblja

Održavanje nastave uz pomoć tehnologije traži visok stupanj vještina nastavnog kadra, zahtjeva osposobljenost za izvođenje nastave i za tehnička pitanja. Takvo osposobljavanje treba biti sastavni dio kontinuiranog usavršavanja nastavnog osoblja. Nastavnici se trebaju usavršavati u tehničkom i metodičkom smislu. Kod metodike treba posebnu pozornost posvetiti oblikovanju interakcije, utjecaju tehnologije na komunikaciju, kao i komunikacijskim vještinama instruktora/mentora. Usavršavanje u tehničkom smislu odnosi se na dodatno usavršavanje nastavnika s ciljem što boljeg snalaženja u virtualnom edukacijskom okružju i novom upravljanju sustavom učenja.

Sustav kontinuiranog usavršavanja pomoćnog osoblja

U obrazovnom sustavu i/ili ustanovi mora postojati velika količina znanja o dostupnim tehnologijama primjenjivim u obrazovanju te posebna radna mjesta za pomoćno osoblje čiji je posao da prate razvoj tehnologije i predlažu najbolja rješenja za vlastitu sredinu. Takvi pojedinci trebaju imati veliko znanje o sustavima za izvođenje nastave, o repozitorijima online materijala te o infrastrukturi potrebnoj za njihovo uvođenje i korištenje. Ključno je konstantno usavršavanje pomoćnog osoblja u tehničkom, ali i metodičkom smislu. Pomoćno osoblje treba razvijati znanje o dizajnu, strukturiranju i organizaciji sadržaja, kao i o načinima i stilovima učenja koje oni omogućuju i potiču.

Kriterij FORMALNO-PРАВNA SPREMНОST OKRUŽENJA

Sustav i kriteriji vrednovanja i promocije sveučilišnih nastavnika

Sustav napredovanja sveučilišnih nastavnika sadrži skup uvjeta koje sveučilišni nastavnici trebaju ispuniti kako bi im se odobrio izbor u više zvanje. Uvjete koje sveučilišni nastavnici trebaju zadovoljiti mogu se klasificirati kao uvjeti za izbor u više znanstveno zvanje, uvjeti koje propisuje Rektorski zbor u pogledu obrazovnog, nastavnog i stručnog rada, te uvjeti koji su propisani Statutom Sveučilišta. U uvjetima Rektorskog zbora za izbor u znanstveno-nastavno zvanje (NN 129/05) (Odluka Rektorskog Zbora o nužnim uvjetima za ocjenu nastavne i stručne djelatnosti u postupku izbora u znanstveno-nastavna zvanja, 2008.) uključena je mogućnost recenziranja i priznavanja e-learning materijala za izbor u više znanstveno-nastavno zvanje.

Sustav vrednovanja i kontrole kvalitete na sveučilištu i fakultetu

Pri uvođenju e-učenja potrebno je voditi računa i o primjeni neovisnog sustava vrednovanja koji omogućuje ocjenjivanje uolikoj mjeri e-učenje podupire postignuće ciljeva učenja (prvenstveno prema mišljenju korisnika) i podiže kvalitetu obrazovanja. Takav sustav vrednovanja bi ponudio podatke o koristima ulaganja u sustav, osobito u pogledu neočekivanih ili nevidljivih troškova implementacije na pozadinske sustave, osoblje i infrastrukturu. Bitna je izgradnja okvira koji bi omogućavao ujednačenost sustava vrednovanja i kontrole kvalitete na svim sveučilištima i fakultetima. Procjena kvalitete je jedan od vidova e-učenja koji traži snažan, centraliziran pristup. Vrsta, raspon i okvir ocjenjivanja moraju biti neovisni i strukturirani da bi se dobili rezultati koji će pomoći u unapređenju sustava, ili koji će dovesti do ispravne odluke treba li sustav odbaciti ili graditi na njemu s novim resursima.

Kriterij RASPOLOŽIVOST SPECIFIČNE INFRASTRUKTURE

Repozitorij digitalnog obrazovnog materijala

Repozitorij (engl. *Library Management System*) je zbirka digitalnog obrazovnog materijala koja omogućuje sustavno upravljanje procesima objavljivanja, pristupa i pohrane nastavnog/obrazovnog sadržaja. Repozitoriji se razlikuju od uobičajenih web kataloga, portala i tražilica jer korisnicima (studentima i znanstveno-nastavnom osoblju) nude strukturiran i organiziran pristup informacijama na način da podržavaju ciljano pronalaženje i korištenje nastavne građe, odnosno visokokvalitetnih i pedagoški oblikovanih radova.

Sustav ispitivanja uz pomoć računala

Sustav ispitivanja uz pomoć računala (engl. *Exam management system*) pruža administrativnu podršku ispitivanju uz pomoć računala (engl. *CAA – Computer Assisted Assessment*). U širem smislu obuhvaća podršku bilo kojem procesu ispitivanja u koji je na bilo koji način uključeno računalo. Uloga računala može biti izravna ili neizravna, od upotrebe tekst procesora do *on-screen* testiranja. U ovom smislu koristi se i termin e-ocjenjivanje (engl. *e-assessment*). U užem smislu, pojam ispitivanja uz pomoć računala koristi se za situacije kada se pri ispitivanju računalo rabi na način da je proces ispitivanja poluautomatiziran ili automatiziran. Primjer poluautomatiziranog procesa ispitivanja je primjerice predavanje uradaka putem umreženog računala (npr. za zadatak esejskog tipa). Sustav ispitivanja uz pomoć računala trebao bi omogućiti i automatizirano ispitivanje, u kojem bi se tehnologija koristila za provedbu cjelokupnog ispitivanja. Sustav ispitivanja uz pomoć računala treba biti uspješno integriran u virtualno edukacijsko okružje.

Mrežni videokonferencijski sustavi

Mrežni videokonferencijski sustavi pružaju podršku organizaciji u održavanju mrežnih videokonferencija. Videokonferencije otvaraju mogućnost za interaktivnu komunikaciju studenata i nastavnika te interaktivni pristup gostiju predavača i drugih eksperata. One čine mogućim predavanje na kojemu mogu istovremeno sudjelovati dislocirani sudionici na velikim udaljenostima. Mrežni videokonferencijski sustavi omogućuju sudionicima verbalno i neverbalno komuniciranje u stvarnom vremenu. Videokonferencije ostvaruju sve veću primjenu u području obrazovanja, na kojem se primarno koriste za održavanje predavanja i konzultacija na daljinu. Svojom mogućnošću prenošenja informacija, znanja i ideja, videokonferencije podupiru tradicionalne oblike učenja i poučavanja postižući uštede u vremenu i troškovima putovanja.

Video i audio streaming

Video i audio streaming je prijenos video materijala (koji obično sadrži i video i audio materijal) i audio materijala „uživo“. Razlikuju se dvije vrste streaminga: streaming na zahtjev (tzv. *on demand*) i live streaming (tzv. *broadcast streaming*). Osnovni uvjet potreban za streaming je dobra propusnost. Video materijal mora biti smješten na video server velike propusnosti podataka, a streaming se može ubrzati na način da vlasnik kreira nekoliko video datoteka koje će biti optimizirane za brzine ovisne o korisniku. Danas se na webu koristi širok raspon audioformata za emitiranje uživo koji u osnovi dijele istu tehnologiju. Za primanje uživo

emitiranih audiomaterijala dostupni su različiti programi, a svaki od njih koristi zaštićeni zvučni ili medijski format. Različiti se formati razlikuju po kvaliteti, no svi su kompatibilni s modemskim vezama. S videomaterijalom je situacija složenija. Kada se uzorak videomaterijala prezentira u elektronskom formatu, on sadrži mnogo više „slojeva“ podataka koje je potrebno komprimirati i pretvoriti u drugi format. Snimanje videa i njegovo spremanje u elektroničkom formatu mnogo je zahtjevnije te zahtjeva dodatni softver.

Proizvodnja video i audio materijala

Proizvodnja i korištenje video i audio materijala u podučavanju i učenju znatno obogaćuju odgojno-obrazovnu komunikaciju. Video i audio materijali donose nove mogućnosti u vizualizaciji i simulaciji kojih nema u klasičnoj nastavi u predavaonici. Alate za proizvodnju multimedijalnih elemenata možemo podijeliti na: zatvoreni kod - komercijalne alate i otvoreni kod - besplatne alate. Neki od najčešće korištenih komercijalnih alata za obradu videa su: *Adobe Premiere, Adobe After Effects, Adobe Encore DVD, Vegas, Windows Movie Maker* i dr. Najčešće korišteni komercijalni alati za obradu zvuka su: *CoolEdit Pro, Acid Pro, CakeWalk Home Studio, WaveLab, Propellerhead Reason*. Od besplatnih alata mogu se izdvojiti: *Jahshaka, Audacity* i dr.

Sustavi za simulacije i virtualnu stvarnost

Sustavi za simulacije i virtualnu stvarnost omogućuju oponašanje stvarnosti i rekreiranje situacija iz stvarnog života te na taj način olakšavaju učenje, smanjuju rizik i sprječavaju nepotrebni utrošak resursa. Simulacije se sve češće koriste u ekonomiji, menadžmentu, vojsci, prometu, tehnici, fizici i dr. Najpoznatiji virtualni svijet je *Second Life* razvijen od strane Linden Laba 2003 godine. S više od 20 milijuna redovitih korisnika *Second Life* je postao jedan od najvećih internetskih servisa na svijetu.

5.2.2. Grupno odlučivanje AHP metodom uz potporu alata TeamEC2000

Programski alat *Expert Choice* (Expert Choice, 2000.) omogućuje provedbu metode AHP kroz nekoliko faza. U početnoj fazi vrši se interaktivno kreiranje hijerarhije problema kao priprema scenarija odlučivanja, zatim se provodi vrednovanje u parovima elemenata hijerarhije (ciljeva, kriterija, podkriterija i alternativa) u top-down ili bottom-up smjeru te se na kraju vrši sinteza svih vrednovanja i po strogo utvrđenom matematičkom modelu određuju se težinski koeficijenti svih elemenata hijerarhije. Zbroj težinskih koeficijenata elemenata na svakom nivou hijerarhije

jednak je 1 što omogućava donositelju odluka da rangira sve elemente u horizontalnom i vertikalnom smislu. Omogućuje se i provjera konzistentnosti rezoniranja donositelja odluke i utvrđivanje ispravnosti rangova alternativa i težinskih vrijednosti kriterija i podkriterija.

Verzija programskog alata *Expert Choice* koja podržava grupno odlučivanje naziva se *TeamExpertChoice2000* i korištena je u testiranju razvijenog AHP modela. Grupno odlučivanje uz potporu alata *TeamExpertChoice2000* je moguće sprovesti na dva načina:

- a) Preko bežičnih daljinskih upravljača - grupno donošenje odluka za petero sudionika i
- b) Preko *EC Decision Portala* - grupno donošenje odluka za veći broj sudionika.

Način koji je korišten u testiranju modela je grupno donošenje odluke preko bežičnih daljinskih upravljača za petero sudionika. Svaki sudionik unosi je individualne procjene u sustav, a sinteza individualnih procjena izvršena je izračunavanjem geometrijske sredine. Aczel i Saaty (Aczel, Saaty, 1983.) matematički su dokazali da ukoliko se koriste recipročne procjene, geometrijska sredina je jedini način kojim se mogu kombinirati individualne procjene. Aczel i Alsina (Aczel, Alsina, 1986.) su dokazali da ukoliko donositelji odluka imaju različiti utjecaj na konačnu odluku, taj utjecaj je potrebno izraziti preko koeficijenta važnosti svakog donositelja odluke te njihove procjene ponderirati tim koeficijentom važnosti. Grupno donošenje odluka temeljeno na AHP/ANP metodi detaljnije je objašnjeno u knjizi "Group decision making: Drawing out and Reconciling Differences" (Saaty & Peniwati, 2008.) i članku profesora Saatyja i profesorice Shang "Group Decision Making: Head-Count versus Intensity of Preference" (Saaty & Shang, 2007.).

Grupno odlučivanje ima određene prednosti i nedostatke. Grupa u većini slučajeva, donosi bolje i kvalitetnije odluke od pojedinca jer posjeduje tzv. višedimenzionalno mišljenje. Individualni donositelj odluke obično generira manji broj ideja, kao i manji broj mogućnosti za rješenje problema. Grupno odlučivanje uključuje sudionike s različitim znanjima i vještinama, koji su motivirani zajedničkim interesom. Postoji i veća spremnost grupe za donošenjem rizičnijih odluka jer se rizik dijeli na sve članove skupine. Grupno donesenu odluku također je lakše sprovesti jer ju prihvaćaju svi ili većina sudionika procesa grupnog odlučivanja. S jedne strane, veći broj sudionika demokratizira odlučivanje, dok s druge strane imamo situaciju da je takvo odlučivanje sporije i često skuplje te postoji opasnost od nametanja mišljenja autoritativnog člana grupe.

Pozitivni aspekti grupnog donošenja odluka su sljedeći:

- grupa često bolje razumije zašto postoji potreba za donošenjem odluke,
- znanje grupe je često veće od znanja pojedinca,
- grupa obično generira veći broj alternativa za rješavanje problema,
- participacija u odlučivanju povećava prihvaćanje odluke od strane članova grupe i
- odgovornost i rizik se dijele na članove grupe.

Negativni aspekti grupnog donošenja odluka su:

- dulje trajanje procesa donošenja odluka,
- opasnost od dominacije autoritativnog člana grupe (tzv. skupnog mišljenja),
- pritisci za slaganjem mogu ograničavati i sputavati članove grupe,
- mogućnost konflikata i neslaganja između članova grupe,
- konkurencija između članova grupe može postati važnija od samog problema i
- postoji tendencija prihvaćanja prvog prihvatljivog rješenja.

Primjenom grupnog odlučivanja uz korištenje daljinskih upravljača i unošenjem individualnih procjena donositelja odluke, izbjegavaju se nedostaci grupnog odlučivanja:

- a) sprječava se nastanak skupnog mišljenja, jedinstvenog mišljenja svih članova skupine do kojeg dolazi zbog velikog pritiska na sudionike koji imaju drugačije, suprotno mišljenje,
- b) svaki sudionik sudjeluje u zajedničkoj diskusiji, ali na njenom završetku individualno unosi svoju procjenu,
- c) zahvaljujući softverskoj i hardverskoj potpori, proces odlučivanja, a naročito obrada rezultata se ubrzava,
- d) konflikti i neslaganje između donositelja odluke mogu se pojaviti, ali samo u diskusiji, odluku svaki pojedinac donosi samostalno i ne treba se cijela grupa složiti oko zajedničke odluke – ona se postiže sintezom individualnih procjena.

Sudionike u procesu odlučivanja možemo podijeliti na moderatora (koordinatora) i sudionike (donositelje odluka). Moderator gradi AHP model i koordinira proces grupnog donošenja odluke (u praksi jedna osoba može graditi model, a druga osoba nadgledati grupnu interakciju), a

donositelje odluka nazivamo sudionicima procesa grupnog odlučivanja. U slučaju potrebe se može uključiti i osoba koja je odgovorna za tehničku potporu (engl. *Technographer*).

Moderator ima pregled i pristup centralnom računalu. Donositelji odluke – sudionici nalaze se u istoj prostoriji te nemaju pristup niti pogled na glavno računalo. Moderator prije početka procesa grupnog odlučivanja unosi imena sudionika, sociodemografske karakteristike, šifre i ostale dostupne informacije, raspoređuje i uključuje daljinske upravljače i namješta softversku i hardversku opremu (ukoliko u procesu ne sudjeluje osoba zadužena za tehničku potporu). Odlučivanje može biti anonimno ili javno. Ako je javno, donositelji odluke su prepoznatljivi svojim imenom i prezimenom te osnovnim sociodemografskim karakteristikama. Moderator vodi i vrši nadzor nad cjelokupnim procesom grupnog odlučivanja. Da bi se grupa fokusirala na istu procjenu, moderator može automatski isključiti daljinske upravljače sudionicima, kako bi spriječio da netko od sudionika ne krene na drugu procjenu prijevremeno. Gašenje daljinskih upravljača između dvije procjene omogućava sudionicima da se usredotoče na diskusiju te da ne unose procjene tako dugo dok diskusija ne završi. Kada je proces grupnog odlučivanja završen, moderator vrši pregled, obradu i analizu rezultata.

Prava i zaduženja moderatora (Expert Choice, Quick Start Guide and Tutorials):

- kreiranje AHP modela,
- strukturiranje i tehnike izgradnje modela,
- generiranje pristupnih šifri i unošenje podataka o sudionicima koji sudjeluju u procesu odlučivanja,
- kombiniranje i integriranje procjena sudionika
- kontinuirana provjera nekonzistentnosti.

Prava i zaduženja sudionika (Expert Choice, Quick Start Guide and Tutorials):

- promjena vlastite šifre,
- unos procjena,
- kreiranje bilješki (objašnjenje procjena),
- analiza svojih rezultata i
- uz dopuštenje moderatora sudionici mogu dobiti uvid u sintezu rezultata grupnog odlučivanja.

Moderator postavlja pitanja sudionicima, a oni preko daljinskih upravljača unose ocjene s obzirom na važnost koju pridjeljuju jednom elementu u odnosu na drugi. Vrednovanje se može vršiti numerički, grafički ili verbalno. U testiranju razvijenog AHP modela, izabrana je opcija numeričkog vrednovanja kao najjednostavnija za ocjenjivanje daljinskim upravljačima. Numerička komparacija se vršila na način da su sudionici odlučivanja unosili ocjene od 1-9 na daljinskom upravljaču te na taj način vršili numeričku procjenu prema Satty-evoj skali relativne važnosti.

Usporedba elemenata u parovima može se vršiti opcijom engl. *importance* (važnost), engl. *preference* (prioritetnost) ili engl. *likelihood* (sličnost). Opcija *importance* se preporuča koristiti kod usporedbe objekata (kriterija i podkriterija, opcija *preference* kod usporedbe alternativa u odnosu na objekte i opcija *likelihood* kod scenarija i nesigurnih događaja, tipa analize rizika (Expert Choice, Quick Start Guide and Tutorials). U našem slučaju je izabran pristup usporedbe elemenata prema važnosti (engl. *importance*) kod kriterija i podkriterija i prema prioritetu (engl. *preference*) kod usporedbe alternativa u odnosu na objekte. Primjenjeno je uspoređivanje «*top down*» metodom.

Sudionici su prije provedbe procesa odlučivanja upozoreni na moguću nekonzistentnost. AHP metoda ima sposobnost identificirati i analizirati nekonzistentnost donositelja odluka u procesu vrednovanja elemenata hijerarhije (detaljnije u poglavlju 5.1.2.1.). Čovjek teško zadržava konzistentnost pri procjenjivanju vrijednosti ili odnosa kvalitativnih elemenata u hijerarhiji. AHP na određen način ublažava ovaj problem tako što mjeri stupanj nekonzistentnosti i o tome obavještava moderatora. Opcija *Inconsistency* u alatu *Expert Choice* identificira moguće greške i nekonzistentnost u procjeni:

Npr. ako se kaže da je A važniji od B i B važniji od C i zatim da je C važniji od A tada u svojoj procjeni nismo konzistentni. Pokazatelj nekonzistentnosti (engl. *Inconsistency ratio*) mora biti manji od 0.1 da bi se rezultati smatrali konzistentnima. Moderator tijekom procesa odlučivanja mora provjeravati indeks nekonzistentnosti i ukazivati na nekonzistentnost ukoliko ona postoji.

5.2.3. Grupno odlučivanje o obliku uvođenja e-učenja na kolegij Matematika

Cilj grupnog odlučivanja provedenog na Fakultetu organizacije i informatike, na Katedri za kvantitativne metode, bio je donijeti odluku o obliku uvođenja e-učenja na kolegij Matematika.

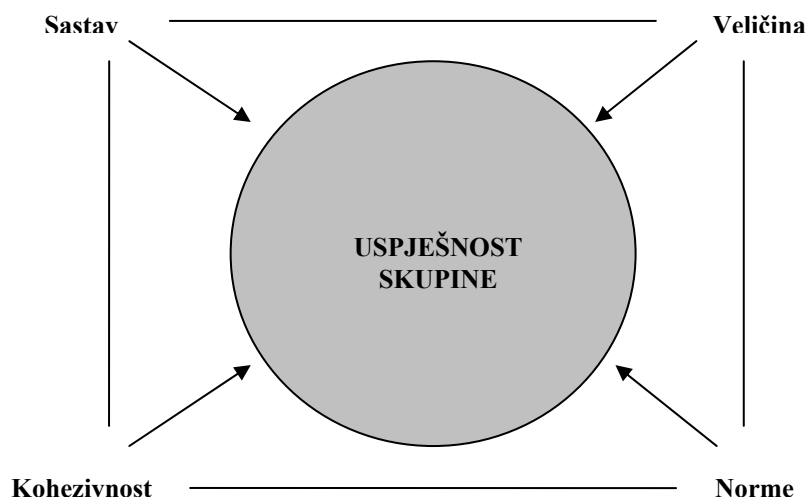
Grupno odlučivanje AHP metodom pomaže grupi da strukturira problem u modelu odlučivanja, odredi prioritete uspoređivanjem u parovima i vrednuje i diskutira o dobivenim rješenjima koristeći analizu osjetljivosti. Organizacija se može fokusirati na strateške vrijednosti dobivenih rješenja i koristiti ih kao preporuke za odluke koje mogu doprinijeti povećanju učinkovitosti poslovanja, bilo profitne, bilo neprofitne organizacije.

Odabir sudionika u postupku testiranja modela te rezultati grupnog odlučivanja o obliku uvođenja e-učenja na kolegij Matematika, opisani su u poglavlju 5.2.3.

5.2.3.1. Izbor sudionika procesa odlučivanja

Grupno odlučivanje predstavlja način donošenja odluka u kojem odluke donosi skupina ljudi koja je strukturirana po različitim kriterijima. Karakteristike skupina koje donose odluku, očitavaju se u zajedničkom interesu skupine, međusobnoj komunikaciji članova skupine te podjeli uloga među članovima skupine kako bi se ostvarili zajednički ciljevi skupine.


Uspjeh grupnog odlučivanja ovisi o sastavu grupe, veličini grupe, normama ponašanja te o postojanju kohezije između članova grupe. Najvažniji čimbenici koji djeluju na uspjeh odlučivanja u grupi prikazani su na slici 5-7.




Slika 5-7. Četiri čimbenika koji utječu na uspješnost grupe u odlučivanju (Sikavica & Bebek, 1994.)

S obzirom na činjenicu da u grupnom odlučivanju odluke donosi veći broj članova, realno je očekivati da će odlučivanje biti drugačije od individualnog jer na zajedničku odluku grupe utječe svaki pojedinac sa svojim znanjima, iskustvima i osobnim značajkama. Velika prednost grupnog odlučivanja je ta da se odgovornost raspoređuje na sve članove grupe. Pojedinci kao članovi grupe lakše odlučuju jer znaju da ne preuzimaju sami odgovornost za eventualne negativne posljedice donesene odluke.


Kakav će biti proces grupnog odlučivanja, ovisi o znanjima i sposobnostima članova skupine, ali i o tome jesu li njihova znanja komplementarna, konkurentna ili istovrsna. Najbolji rezultati u grupnom odlučivanju obično se postižu ako su znanja članova skupine koja odlučuje komplementarna, a najslabiji rezultati kada su znanja članova skupine konkurentna odnosno istovrsna. Slika 5-8. daje prikaz različitih skupina donositelja odluka s obzirom na znanja njihovih članova. U prikazu su korišteni Vennovi dijagrami koje je osmislio John Venn u devetnaestom stoljeću. Vennovi dijagrami su sastavljeni od preklapajućih krugova, područje unutar kruga predstavlja sadržaj skupa, a područje izvan njega predstavlja sadržaj njegovog komplementa (skupa svih stvari koje nisu članovi razmatranog skupa).



a) članovi skupine s komplementarnim znanjima



b) članovi skupine s konkurentnim znanjima



c) članovi skupine s istovrsnim ili sličnim znanjima

Slika 5-8. Skupine donositelja odluka s obzirom na znanja njihovih članova (Sikavica & Bebek, 1994.)

Izbor sudionika procesa grupnog odlučivanja o obliku uvođenja e-učenja na kolegij Matematika, izvršen je s ciljem postizanja komplementarnosti znanja sudionika procesa odlučivanja. Detaljan opis ekspertize sudionika nalazi se u tablici 5-8.

Tablica 5-8. Ekspertiza sudionika procesa grupnog odlučivanja o obliku uvođenja e-učenja na kolegij Matematika

SUDIONIČK	EKSPERTIZA
SUDIONIČK 1	<ul style="list-style-type: none"> - doktorirala na PMF-MO - znanstveno-nastavno zvanje izvanredni profesor - prodekanica za znanost - nositeljica matematičkih predmeta na preddiplomskoj, diplomskoj i poslijediplomskoj razini (nositeljica kolegija Matematika I i II, Matematičke metode, Diskretne strukture i teorija grafova (predavač 12 godina)) - više znanstvenih i stručnih radova iz područja metodike nastave matematike - znanstveni radovi iz područja teorije odlučivanja vezano uz e-učenje - predavač na više stručnih i znanstvenih skupova s temama iz metodike - sudjelovala u više međunarodnih projekata vezanih uz e-učenje (Tempus, Eureka) - voditeljica Referalnog centra za prijavljivanje projekata e-obrazovanja te projektnog tima u CARN-etu koji je izradio preporuke za standardizaciju i valorizaciju e-learning materijala u Hrvatskoj.
SUDIONIČK 2	<ul style="list-style-type: none"> - profesorica matematike - asistentica na kolegiju Matematika na Fakultetu organizacije i informatike - drži seminarsku nastavu iz nekoliko matematičkih kolegija na dodiplomskom studiju: Matematika 1, Matematika 2 i Financijska matematika - polaznica doktorskog znanstvenog poslijediplomskog studija na PMF-u (Matematički odjel) - prisustvovala u svojstvu predavača i/ili sudionika na više stručnih skupova iz metodike nastave matematike na PMF-u - sudjelovala u više radionica vezanih uz e-učenje (Web CT, Moodle) i dr. - članica Referalnog centra za prijavljivanje projekata e-obrazovanja.

SUDIONIČ 3	<ul style="list-style-type: none"> - diplomirani informatičar - asistent na kolegiju Informatika na Fakultetu organizacije i informatike - za vrijeme studija na FOI-u, demonstrator iz kolegija Matematika - planiranje i kreiranje e-learning materijala za matematičke kolegije - znanstveni i stručni radovi u području informacijske sigurnosti i e-učenja - rad na projektu kreiranja strategije uvođenja e-učenja na Fakultet organizacije i informatike - kreiranje i postavljanje nastavnih sadržaja na nekoliko LMS sustava - završio CARNet-ovu E-Learning Akademiju (ELA), smjer Menadžment.
SUDIONIČ 4	<ul style="list-style-type: none"> - diplomirani informatičar - stručni suradnik na Fakultetu organizacije i informatike u naslovnom zvanju asistenta - web master te administrator LMS sustava na FOI-u - stručni radovi iz područja e-učenja te sudjelovanje na mnogim skupovima iz područja e-učenja - višegodišnje iskustvo u radu s e-učenjem - stručnjak za LMS sustave te instrukcijski dizajn - rad na projektu kreiranja strategije uvođenja e-učenja na Fakultet organizacije i informatike - završio CARNet-ovu E-Learning Akademiju (ELA), smjer Course Design.
SUDIONIČ 5	<ul style="list-style-type: none"> - apsolvent na Fakultetu organizacije i informatike - demonstrator na kolegiju Matematika i Matematičke metode za informatičare - član Referalnog centra za prijavljivanje projekata e-obrazovanja - zaposlen u poduzeću Lucidus d.o.o. u sklopu kojeg je sudjelovao u izradi kompletnog CMS sustava te na izmjeni nekoliko modula LMS sustava.

5.2.3.2. Rezultati grupnog odlučivanja

Nakon provedenog grupnog odlučivanja dobiveni su rezultati koji se mogu analizirati i interpretirati zasebno za svakog sudionika i grupno kao sinteza rezultata sudionika procesa grupnog odlučivanja.

Na slici 5-9. *Rezultati grupnog odlučivanja AHP metodom za kolegij Matematika – Prioriteti alternativa* prikazani su prioriteti alternativa dobiveni sintezom procjena sudionika odlučivanja.

Alternativa „Hibridna ili mješovita nastava“ ima najveći prioritet od 0,429, te možemo zaključiti da se kao rezultat grupnog odlučivanja preporučuje uvođenje hibridnog modela nastave na kolegij Matematika na Katedri za kvantitativne metode na Fakultetu organizacije i informatike. Alternativa „Nastava uz pomoć ICT-a“ ima nešto manji prioritet (0,323) od prvorangirane alternative i time pokazuje trenutno stanje na kolegiju Matematika na kojem se u velikoj mjeri koristi informatička tehnologija za poboljšanje kvalitete nastave, ali isto tako pokazuje i spremnost za prelazak na višu stepenicu i uvođenje hibridnog modela učenja koji je

prvorangirana alternativa. Treća po redu rangirana alternativa je „Online obrazovanje“ s prioritetom 0,140 ispred četvrtorangirane „Klasične nastave (f2f)“ s prioritetom od 0,108, što možemo interpretirati kao vrlo ohrabrujući pokazatelj spremnosti za uvođenje e-učenja na kolegij Matematika. Zanimljivo je da su sudionici između klasične nastave i potpunog online pristupa, prednost dali potpunom online obrazovanju na kolegiju Matematika.

Klasična nastava (f2f, licem u lice)	,108
Nastava uz pomoć ICT	,323
Hibridna ili mješovita nastava	,429
Online obrazovanje	,140

Slika 5-9. Rezultati grupnog odlučivanja AHP metodom za kolegij Matematika – Prioriteti alternativa

Na slici 5-10. *Rezultati grupnog odlučivanja AHP metodom za kolegij Matematika – Težinski koeficijenti kriterija i podkriterija* prikazano je hijerarhijsko stablo s težinskim koeficijentima kriterija i podkriterija. U tablici 5-9. nalazi se pregled dobivenih težinskih koeficijenata kriterija i podkriterija.



Slika 5-10. Rezultati grupnog odlučivanja AHP metodom za kolegij Matematika – Hijerarhijsko stablo s težinskim koeficijentima kriterija i podkriterija

Tablica 5-9. Rezultati grupnog odlučivanja AHP metodom za kolegij Matematika - Pregled težinskih koeficijenata kriterija i podkriterija

KRITERIJI I PODKRITERIJI	TEŽINSKI KOEFICIJENTI
FORMALNO – PRAVNA SPREMNOST OKRUŽENJA	0,351
Sustav i kriteriji vrednovanja i promocije sveučilišnih nastavnika	0,175
Sustav vrednovanja i kontrole kvalitete na sveučilištu i fakultetu	0,175
ORGANIZACIJSKA I STRATEŠKA SPREMNOST OKRUŽENJA	0,253
Sveučilišni razvojni okvir	0,098
Financijska spremnost sveučilišta i fakulteta	0,091
Razvojna strategija fakulteta	0,064
LJUDSKI RESURSI	0,204
Sustav kontinuiranog usavršavanja nastavnog osoblja	0,069
Raspoloživost pomoćnog osoblja za tehničku potporu e-učenju	0,033
Sustav kontinuiranog usavršavanja pomoćnog osoblja	0,032
Raspoloživost pomoćnog osoblja za grafičko oblikovanje, animaciju i video	0,025
Raspoloživost pomoćnog osoblja za metodičku potporu e-učenju	0,023
Specijalizirani centri potpore e-učenju na sveučilištu	0,022
RASPOLOŽIVOST TEMELJNE ICT INFRASTRUKTURE	0,100
Integralni sustav upravljanja procesom obrazovanja (MLEs)	0,042
Sustav kontinuiranog usavršavanja pomoćnog osoblja	0,032
Računalna opremljenost nastavnika i studenata	0,025
Mrežna infrastruktura	0,023
Tehnička opremljenost predavaonica i učionica na fakultetu	0,010
RASPOLOŽIVOST SPECIFIČNE INFRASTRUKTURE	0,092
Sustav ispitivanja uz pomoć računala	0,031
Repozitorij digitalnog obrazovnog materijala	0,023
Mrežni videokonferencijski sustavi	0,013
Video i audio streaming	0,011
Proizvodnja audio i video materijala	0,008
Sustavi za simulacije i virtualnu stvarnost	0,005

Kriterij „Formalno-pravna spremnost okruženja“ prepoznat je kao najvažniji s težinskim koeficijentom od 0,351. Razlozi koji su doprinijeli važnosti ovog kriterija su velika nastojanja akademske zajednice da uspostavi sustav vrednovanja sveučilišnih nastavnika koji bi obuhvaćao evaluaciju e-learning materijala i priznavao sve napore i uloženi rad i trud u osmišljavanje i kreiranje online materijala i razvoj online kolegija. Formalno uspostavljen sustav nagrađivanja za rad u području e-učenja najveći je motivator za pokretanje e-učenja i njegovog uvođenja u sustav visokog školstva. Dodatni razlog je i sustav vrednovanja i kontrole kvalitete na sveučilištu i fakultetu na čijoj se uspostavi i primjeni naporno radi u sklopu mnogih projekata na sveučilištima u Hrvatskoj (Referalni centar za upravljanje kvalitetom, 2006.).

Kriterij „Organizacijska i strateška spremnost okruženja“ je drugi kriterij po važnosti s težinskim koeficijentom 0,253 te obuhvaća podkriterije: Sveučilišni razvojni okvir (0,098), Financijska spremnost sveučilišta i fakulteta (0,091) i Razvojna strategija fakulteta (0,064). Velika važnost ovog kriterija za donošenje strateške odluke o obliku uvođenja e-učenja na kolegij Matematika, u potpunosti je razumljiva i u skladu s rezultatima anketiranja (vidi poglavlje 4.4.1.).

„Ljudski resursi“ kao treći kriterij po važnosti s težinskim koeficijentom 0,204 obuhvaća sljedeće podkriterije: Sustav kontinuiranog usavršavanja nastavnog osoblja (0,069), Raspoloživost pomoćnog osoblja za tehničku potporu e-učenju (0,033), Sustav kontinuiranog usavršavanja pomoćnog osoblja (0,032), Raspoloživost pomoćnog osoblja za grafičko oblikovanje, animaciju i video (0,025), Raspoloživost pomoćnog osoblja za metodičku potporu e-učenju (0,023) i Specijalizirani centri potpore e-učenju na sveučilištu (0,022). Važnost kriterija „Ljudski resursi“ prepoznata je kao velika s obzirom na malu raspoloživost pomoćnog osoblja za potporu sveučilišnim nastavnicima i studentima pri uvođenju i uporabi tehnologija e-učenja te prepoznavanje potrebe za nužnim poboljšanjem sustava kontinuiranog usavršavanja nastavnog i pomoćnog osoblja.

Kriterij „Raspoloživost temeljne ICT infrastrukture“ s težinskim koeficijentom 0,100 i kriterij „Raspoloživost specifične infrastrukture“ s težinskim koeficijentom 0,092 prepoznati su kao važni, ali ne i kao ključni u donošenju odluke o obliku uvođenja e-učenja na kolegij Matematika. Razlog je taj što se s većinom potrebne temeljne i specifične infrastrukture raspolaže, a u slučaju

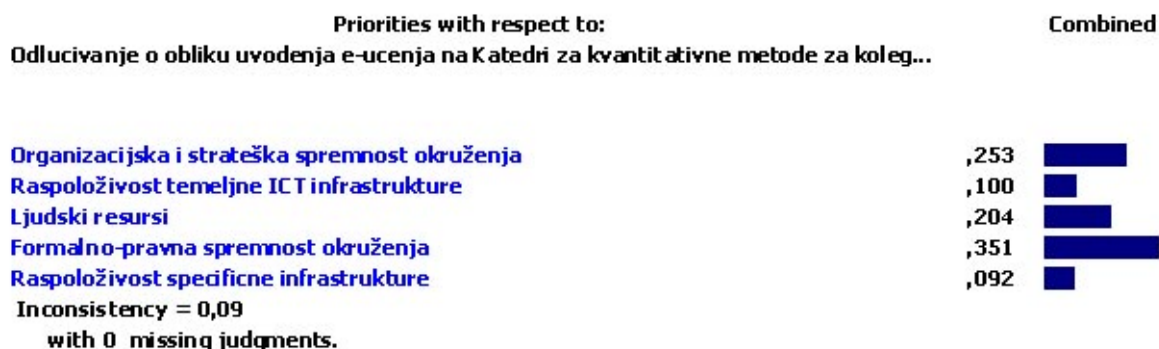
da se osjeti potreba za unapređenjem postojeće infrastrukture, postoje već dobro poznati i isprobani načini rješavanja takvih problema.

Na slici 5-11. *Provedba i rezultati uspoređivanja AHP metodom na razini kriterija* prikazan je prvi korak numeričkog uspoređivanja – usporedba kriterija u parovima u alatu *TeamEC2000*. Nakon završene komparacije važnosti kriterija u parovima, dobiveni su težinski koeficijenti kriterija.

**Compare the relative importance with respect to: Odlucivanje o obliku
uvedenja e-ucenja na Katedri za kvantitativne metode za kolegij
Matematika na IS-u**

Circle one number per row below using the scale:
1 = Equal 3 = Moderate 5 = Strong 7 = Very strong 9 = Extreme

1	Organizacijska i strateška spremnost okruženja	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Raspoloživost temeljne ICT infrastrukture
2	Organizacijska i strateška spremnost okruženja	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Ljudski resursi
3	Organizacijska i strateška spremnost okruženja	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Formalno-pravna spremnost okruženja
4	Organizacijska i strateška spremnost okruženja	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Raspoloživost specifične infrastrukture
5	Raspoloživost temeljne ICT infrastrukture	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Ljudski resursi
6	Raspoloživost temeljne ICT infrastrukture	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Formalno-pravna spremnost okruženja
7	Raspoloživost temeljne ICT infrastrukture	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Raspoloživost specifične infrastrukture
8	Ljudski resursi	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Formalno-pravna spremnost okruženja
9	Ljudski resursi	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Raspoloživost specifične infrastrukture
10	Formalno-pravna spremnost okruženja	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	Raspoloživost specifične infrastrukture




Slika 5-11. Provedba i rezultati numeričkog uspoređivanja AHP metodom na razini kriterija

Cjelokupni postupak i rezultati grupnog odlučivanja AHP metodom nalaze se u prilogu 5 doktorske disertacije (izvještaj generiran od strane alata TeamEC200).

Rezultati se u programskom alatu *Expert Choice* prikazuju i preko analize osjetljivosti. Kao što je već spomenuto, analiza osjetljivosti se provodi s ciljem da se vidi u kojoj mjeri se promjene ulaznih podataka odražavaju na promjene izlaznih rezultata. Može se pretpostaviti da procjene donositelja odluke mogu varirati u nekim rasponima, a da te promjene još uvijek budu u skladu s preferencijama donositelja odluke. Da bi se došlo do zaključka da li je rang lista alternativa dovoljno stabilna u odnosu na prihvatljive promjene ulaznih podataka preporuča se provjera prioriteta alternativa za različite kombinacije ulaznih podataka.


Alat *Expert Choice* nudi pet opcija analize osjetljivosti: *Dynamic*, *Performance*, *Gradient*, *Head to head* i *2 D*. Analiza se može izvesti iz cilja ili bilo kojeg drugog objekta u hijerarhiji. Analiza osjetljivosti iz čvora cilja pokazat će osjetljivost alternativa prema svim objektima u hijerarhijskom stablu.

Preko analize osjetljivosti – opcije *Dynamic* moguće je vidjeti kako se dinamički mijenjaju prioriteta alternativa ukoliko se mijenjaju težine pojedinih kriterija. Moguć je prikaz simulacije na svim razinama u modelu. Ovaj tip analize osjetljivosti ima i opciju *Components* (Komponente) u kojoj je moguće vidjeti udjele težina pojedinih kriterija u ukupnom prioritetu alternativa. Pomoću opcije *Dynamic* dobiva se odgovor na pitanje: "Kolika bi trebala biti težina pojedinog kriterija da bi određena alternativa dobila prednost pred drugom alternativom?". Slika 5-12. prikazuje Analizu osjetljivosti – opciju *Dynamic* iz čvora cilja uz uključenu opciju *Components*.



Slika 5-12. Analiza osjetljivosti – opcija *Dynamic* iz čvora cilja

Analiza osjetljivosti – opcija *Performance* prikazuje prioritete alternativa te ih stavlja u odnos s težinama pojedinih objekata i/ili svim objektima zajedno. Simulacija se vrši na način da se mijenjanjem težina pojedinih objekata mogu promatrati promjene u prioritetima alternativa. Slika 5-13. prikazuje Analizu osjetljivosti – opciju *Performance* iz čvora cilja.



Slika 5-13. Analiza osjetljivosti – opcija *Performance* iz čvora cilja

Analiza osjetljivosti – opcija *Gradient* daje uvid u prioritete alternativa u odnosu na težinu jednog objekta (kriterija ili podkriterija). Ona omogućuje analizu osjetljivosti prioriteta alternativa na promjene težina pojedinih kriterija. Vertikalna linija na prikazima označava koeficijent važnosti za odabrani kriterij. Slike 5-14. – 5-18. prikazuju Analizu osjetljivosti – opciju *Gradient* za sve kriterije u modelu.


Na slici 5-14. vidi se da s porastom težine kriterija "Organizacijska i strateška spremnost okruženja" prioritet alternative "Nastava uz pomoć ICT-a" raste, prioritet alternative "Klasična nastava" se gotovo ne mijenja, dok prioriteti alternativa "Online obrazovanje" i "Hibridna ili mješovita nastava" lagano opadaju s porastom težine tog kriterija.

Slika 5-15. pokazuje da se s porastom težine kriterija "Raspoloživost temeljne ICT infrastrukture" prioriteti alternativa "Nastava uz pomoć ICT-a" i "Klasična nastava" gotovo ne mijenjaju, prioritet alternative "Online obrazovanje" je u opadanju, dok prioritet alternative "Hibridna ili mješovita nastava" bilježi lagani rast s porastom težine tog kriterija.


Na slici 5-16. vidi se da s porastom težine kriterija "Ljudski resursi" prioriteti alternativa "Online obrazovanje" i "Klasična nastava" se gotovo ne mijenjaju, prioritet alternative "Nastava uz pomoć ICT-a" bilježi lagani porast s rastom težine kriterija, dok prioritet alternative "Hibridna ili mješovita nastava" lagano opada.

Iz slike 5-17. vidimo da s porastom težine kriterija "Formalno-pravna spremnost okruženja" prioriteti alternativa "Online obrazovanje" i "Hibridna ili mješovita nastava" gotovo podjednako rastu, dok prioriteti alternativa "Klasična nastava" i "Nastava uz pomoć ICT-a" lagano opadaju s porastom težine tog kriterija. Prioritet alternative "Nastava uz pomoć ICT-a" bilježi nešto jači pad od prioriteta alternative "Klasična nastava".

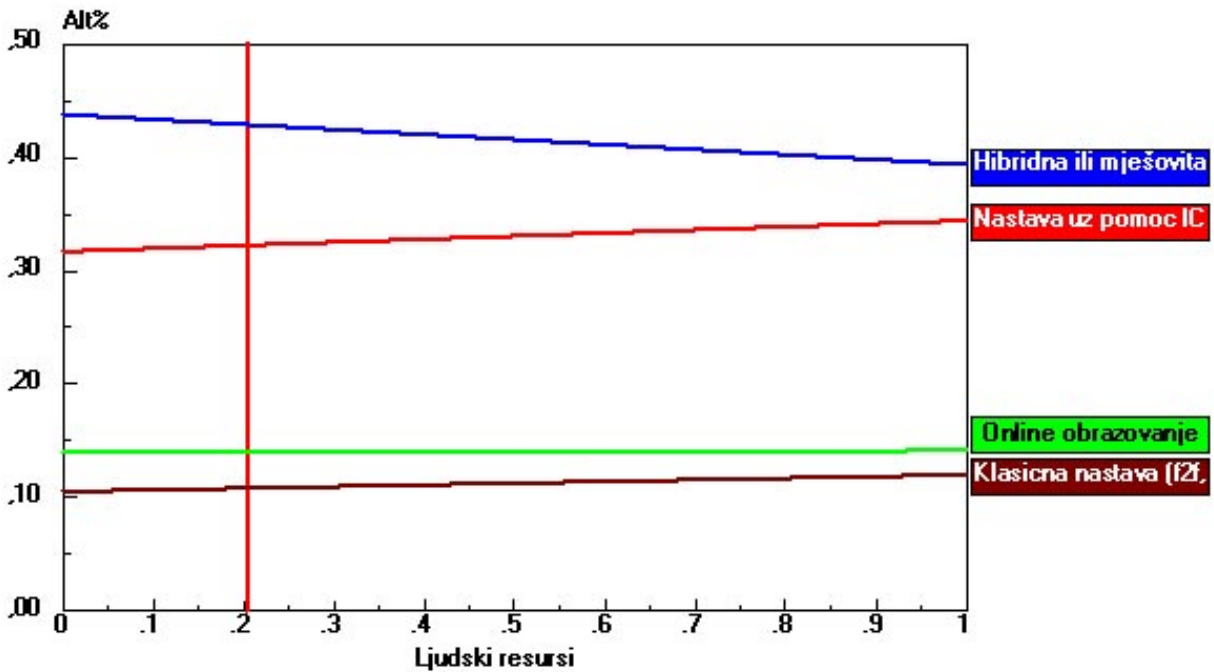
Na slici 5-18. vidi se da s porastom težine kriterija "Raspoloživost specifične infrastrukture" prioritet alternative "Nastava uz pomoć ICT-a" ostaje nepromjenjiv, prioriteti alternativa "Klasična nastava" i "Hibridna ili mješovita nastava" bilježe lagani porast, dok prioritet alternative "Online obrazovanje" lagano pada s porastom težine kriterija "Raspoloživost specifične infrastrukture".




Slika 5-14. Analiza osjetljivosti – opcija *Gradient* za kriterij „Organizacijska i strateška spremnost okruženja“




Slika 5-15. Analiza osjetljivosti – opcija *Gradient* za kriterij „Raspoloživost temeljne ICT infrastrukture“



Slika 5-16. Analiza osjetljivosti – opcija *Gradient* za kriterij „Ljudski resursi“



Slika 5-17. Analiza osjetljivosti – opcija *Gradient* za kriterij „Formalno-pravna spremnost okruženja“



Slika 5-18. Analiza osjetljivosti – opcija *Gradient* za kriterij „Raspoloživost specifične infrastrukture“

Analiza osjetljivosti – opcija *Head to head* uspoređuje dvije alternative u odnosu na sve objekte. Jedna alternativa se prikazuje na lijevoj strani grafa, a druga na desnoj. Jednostavnim korištenjem opcija moguće je vizualizirati odnose razmatranih alternativa u svim parovima.

Preko opcije *Head to head* na glavnoj alatnoj traci mogu se birati alternative za koje se želi vidjeti analiza. Slike 5-19. – 5-24. prikazuju analize osjetljivosti - opcija *Head to head* za sve parove alternativa. Na slici 5-19. se vidi da alternativa "Nastava uz pomoć ICT" ima prednost pred alternativom "Klasična nastava" po svim kriterijima te se ujedno vidi i ukupna ponderirana prednost alternative "Nastava uz pomoć ICT". Kriterijima, po kojima ima prednost alternativa "Nastava uz pomoć ICT", pridruženi su pravokutnici odgovarajućih površina usmjereni u desno. Ukupna prednost druge alternative (Nastava uz pomoć ICT) nad prvom (Klasična nastava) prikazana je pravokutnikom na najnižoj razini koji je orijentiran u desno.

Na slici 5-20. se vidi da alternativa "Hibridna ili mješovita nastava" ima prednost pred alternativom "Klasična nastava" po svim kriterijima, s najvećim postotkom kod kriterija

"Formalno-pravna spremnost okruženja" te se može vidjeti i ukupna ponderirana prednost alternative "Hibridna ili mješovita nastava" s visokim postotkom od 31%.


Na slici 5-21. se vidi po kojim kriterijima alternativa "Online obrazovanje" ima prednost pred alternativom "Klasična nastava" i obratno, te ukupna ponderirana prednost prve alternative. Kriterijima, po kojima ima prednost alternativa "Online obrazovanje", pridruženi su pravokutnici odgovarajućih površina usmjereni ulijevo (kriteriji Ljudski resursi i Formalno-pravna spremnost okruženja), a pravokutnici pridruženi kriterijima po kojima ima prednost alternativa "Klasična nastava" orijentirani su udesno (kriterij Organizacijska i strateška spremnost okruženja). Ukupna prednost alternative "Online obrazovanje" nad drugom "Klasična nastava" prikazana je pravokutnikom na najnižoj razini koji je orijentiran ulijevo.

Iz slike 5-22. vidimo da alternativa "Nastava uz pomoć ICT" po svim kriterijima ima veći prioritet pred alternativom "Online obrazovanje". Najveću prednost ima po kriteriju "Organizacijska i strateška spremnost okruženja", a najmanju po kriteriju "Raspoloživost specifične infrastrukture".

Na slici 5-23. se vidi da alternativa "Hibridna ili mješovita nastava" ima prednost pred alternativom "Online obrazovanje" po svim kriterijima, s najvećim postotkom kod kriterija "Formalno-pravna spremnost okruženja". Najmanju prednost alternativa "Hibridna ili mješovita nastava" ima po kriteriju "Raspoloživost specifične infrastrukture".


Pri usporedbi prioriteta alternative "Hibridna ili mješovita nastava" i alternative "Nastava uz pomoć ICT", prednost je na strani "Hibridne ili mješovite nastave". Najveći utjecaj ima kriterij "Formalno-pravna spremnost okruženja", a nakon njega kriterij "Raspoloživost temeljne ICT infrastrukture". Ukupna prednost alternative "Hibridna ili mješovita nastava" nad alternativom "Nastava uz pomoć ICT" nije velika, a prikazana je pravokutnikom na najnižoj razini koji je orijentiran ulijevo za 10%.

Weighted head to head between Klasična nastava (f2f, licem u lice) and Nastava uz pomoć ICT




Slika 5-19. Analiza osjetljivosti – opcija *Head to head* za alternative „Klasična nastava“ i „Nastava uz pomoć ICT“

Weighted head to head between Hibridna ili mješovita nastava and Klasična nastava (f2f, licem u lice)




Slika 5-20. Analiza osjetljivosti – opcija *Head to head* za alternative „Hibridna ili mješovita nastava“ i „Klasična nastava“

Weighted head to head between Online obrazovanje and Klasična nastava
(f2f, licem u lice)




Slika 5-21. Analiza osjetljivosti – opcija *Head to head* za alternative „Online obrazovanje“ i „Klasična nastava“

Weighted head to head between Online obrazovanje and Nastava uz pomoc ICT



Slika 5-22. Analiza osjetljivosti – opcija *Head to head* za alternative „Online obrazovanje“ i „Nastava uz pomoć ICT-a“

Weighted head to head between Online obrazovanje and Hibridna ili mješovita nastava



Slika 5-23. Analiza osjetljivosti – opcija *Head to head* za alternative „Online obrazovanje“ i „Hibridna ili mješovita nastava“

Weighted head to head between Hibridna ili mješovita nastava and Nastava uz pomoć ICT



Slika 5-24. Analiza osjetljivosti – opcija *Head to head* za alternative „Hibridna ili mješovita nastava“ i „Nastava uz pomoć ICT-a“

Analiza osjetljivosti – opcija 2 D izdvaja dva izabrana objekta (kriterija ili podkriterija) i stavlja ih u odnos s alternativama. Na svakoj osi grafa je prikazan jedan kriterij. Graf je podijeljen na kvadrante te ona alternativa koja se nalazi u gornjem desnom kvadrantu ima najveći prioritet s gledišta ta dva objekta. Alternative su optimalnije što su bliže tom kvadrantu.

Slike 5-25. – 5-34. prikazuju Analize osjetljivosti – opciju 2 D za različite parove kriterija. Na slici 5-25. vidimo da s aspekta kriterija „Temeljna ICT infrastruktura“ i kriterija „Organizacijska i strateška spremnost okruženja“ najveći prioritet imaju alternative „Hibridna ili mješovita nastava“ i „Nastava uz pomoć ICT“. Ako uspoređujemo te dvije alternative, prednost ima alternativa „Hibridna ili mješovita nastava“ s obzirom da ima veći prioritet vezano uz kriterij „Temeljna ICT infrastruktura“, dok obje alternative imaju gotovo isti prioritet s aspekta kriterija „Organizacijska i strateška spremnost okruženja“.

Na slici 5-26. vidimo da s aspekta kriterija „Temeljna ICT infrastruktura“ i kriterija „Formalno-pravna spremnost okruženja“ najveći prioritet ima „Hibridna ili mješovita nastava“ dok se alternativa „Nastava uz pomoć ICT“ nalazi na granici dva gornja kvadranta. Ako promatramo odnos alternativa „Online obrazovanje“ i „Klasična nastava“, alternativa „Online obrazovanje“ ima neznatno veći prioritet.

Na slici 5-27. vidimo da su alternative „Hibridna ili mješovita nastava“ i „Nastava uz pomoć ICT“ najvećeg prioriteta s aspekta kriterija „Organizacijska i strateška spremnost okruženja“ i kriterija „Ljudski resursi“. Veći prioritet ipak ima alternativa „Hibridna ili mješovita nastava“ jer s aspekta kriterija „Ljudski resursi“ ima određenu prednost.

Slika 5-28. prikazuje znatan prioritet alternative „Hibridna ili mješovita nastava“ u odnosu na druge alternative. Kriteriji „Temeljna ICT infrastruktura“ i „Specifična infrastruktura“ doprinose i gotovo jednakom prioritetu alternativa „Online obrazovanje“ i „Klasična nastava“, s laganom prednosti alternative „Klasična nastava“ pod utjecajem oba kriterija.

Ako promatramo prioritete alternativa s aspekta kriterija „Ljudski resursi“ i kriterija „Raspoloživost temeljne ICT infrastrukture“ (slika 5-29.), vidimo da alternativa „Hibridna ili

mješovita nastava“ ima najveći prioritet zahvaljujući kriteriju „Temeljna ICT infrastruktura“ koji doprinosi njenoj prednosti pred alternativom „Nastava uz pomoć ICT“. Prema kriteriju „Ljudski resursi“ alternativa „Hibridna ili mješovita nastava“ ima samo laganu prednost. Alternative „Online obrazovanje“ i „Klasična nastava“ prekapaju se u jednom dijelu, s time da alternativa „Online obrazovanje“ ima prednost u kriteriju „Ljudski resursi“, a alternativa „Klasična nastava“ u kriteriju „Temeljna ICT infrastruktura“.

Slika 5-30. prikazuje znatan prioritet alternative „Hibridna ili mješovita nastava“ u odnosu na druge alternative. Kriteriji „Temeljna ICT infrastruktura“ i „Formalno-pravna spremnost okruženja“ smjestili su alternativu „Nastava uz pomoć ICT“ na granicu donjeg i gornjeg desnog kvadranta i tako poprilično odvojili prioritete alternativa „Hibridna ili mješovita nastava“ i „Nastava uz pomoć ICT“. Što se tiče alternativa „Online obrazovanje“ i „Klasična nastava“, alternativa „Online obrazovanje“ ima veći prioritet pod utjecajem kriterija „Formalno-pravna spremnost okruženja“.


Na slici 5-31. vidimo da su alternative „Hibridna ili mješovita nastava“ i „Nastava uz pomoć ICT“ gotovo istog prioriteta gledajući s aspekta kriterija „Organizacijska i strateška spremnost okruženja“, međutim gledajući s aspekta kriterija „Specifična infrastruktura“, prednost ima alternativa „Hibridna ili mješovita nastava“. Alternative „Online obrazovanje“ i „Klasična nastava“ imaju gotovo iste prioritete s aspekta kriterija „Specifična infrastruktura“, međutim ako uključimo i aspekt kriterija „Organizacijska i strateška spremnost okruženja“, možemo vidjeti prednost alternative „Online obrazovanje“.

Slika 5-32. prikazuje znatan prioritet alternative „Hibridna ili mješovita nastava“ u odnosu na druge alternative ponajviše pod utjecajem kriterija „Specifična infrastruktura“. Alternative „Online obrazovanje“ i „Klasična nastava“ se preklapaju u jednom manjem dijelu, s laganom prednosti alternative „Online obrazovanje“ pod utjecajem kriterija „Ljudski resursi“.


Slika 5-33. prikazuje znatan prioritet alternative „Hibridna ili mješovita nastava“ u odnosu na druge alternative pod utjecajem kriterija „Formalno-pravna spremnost okruženja“ i „Ljudski resursi“. Alternativa „Nastava uz pomoć ICT“ nalazi se na sjecištu gornjeg i donjeg desnog

kvadranta, dok alternativa „Online obrazovanje“ pokazuje prednost pred alternativom „Klasična nastava“.


Ako promatramo prioritete alternativa s aspekta kriterija „Raspoloživost specifične infrastrukture“ i kriterija „Formalno-pravna spremnost okruženja“ (slika 5-34.), vidimo da alternativa „Hibridna ili mješovita nastava“ ima najveći prioritet u odnosu na druge alternative. Alternative „Nastava uz pomoć ICT“ nalazi se na granici gornjeg lijevog i gornjeg desnog kvadranta i gubi svoju prednost pod utjecajem kriterija „Formalno-pravna spremnost okruženja“. Alternative „Online obrazovanje“ i „Klasična nastava“ su smještene u donjem lijevom kvadrantu, imaju gotovo isti prioritet gledajući s aspekta kriterija „Raspoloživost specifične infrastrukture“, međutim pod utjecajem kriterija „Formalno-pravna spremnost okruženja“, prioritet ima alternativa „Online obrazovanje“.




Slika 5-25. Analiza osjetljivosti – opcija 2 D za kriterije „Temeljna ICT infrastruktura“ i „Organizacijska i strateška spremnost okruženja“




Slika 5-26. Analiza osjetljivosti – opcija 2 D za kriterije „Organizacijska i strateška spremnost okruženja“ i „Formalno-pravna spremnost okruženja“




Slika 5-27. Analiza osjetljivosti – opcija 2 D za kriterije „Ljudski resursi“ i „Organizacijska i strateška spremnost okruženja“




Slika 5-28. Analiza osjetljivosti – opcija 2 D za kriterije „Specificka infrastruktura“ i „Temeljna ICT infrastruktura“




Slika 5-29. Analiza osjetljivosti – opcija 2 D za kriterije „Ljudski resursi“ i „Temeljna ICT infrastruktura“




Slika 5-30. Analiza osjetljivosti – opcija 2 D za kriterije „Formalno-pravna spremnost okruženja“ i „Temeljna ICT infrastruktura“



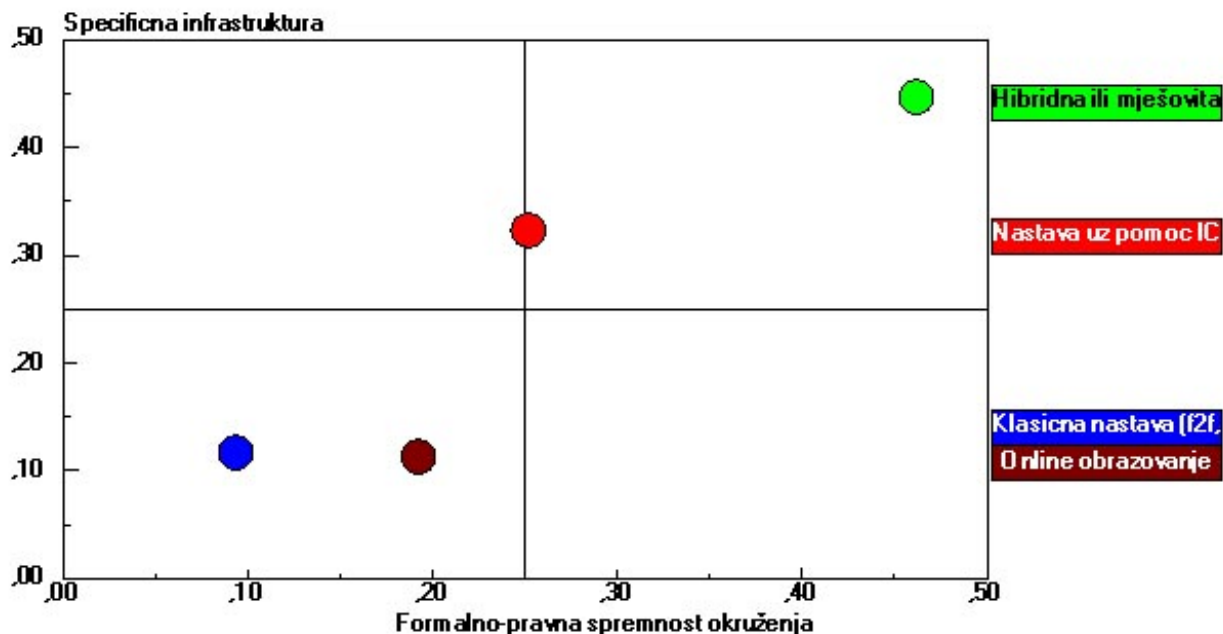
Slika 5-31. Analiza osjetljivosti – opcija 2 D za kriterije „Specifična infrastruktura“ i „Organizacijska i strateška spremnost okruženja“



Slika 5-32. Analiza osjetljivosti – opcija 2 D za kriterije „Ljudski resursi“ i „Specifična infrastruktura“



Slika 5-33. Analiza osjetljivosti – opcija 2 D za kriterije „Ljudski resursi“ i „Formalno-pravna spremnost okruženja“




Slika 5-34. Analiza osjetljivosti – opcija 2 D za kriterije „Specifična infrastruktura“ i „Formalno-pravna spremnost okruženja“

Analiza osjetljivosti služi nam i za provjeru da li nam je rezultat odlučivanja odnosno rang alternativa stabilan. Za provjeru stabilnosti rezultata služi nam dinamička analiza osjetljivosti (opcija *Dynamic*). Ukoliko konačan rezultat ostaje isti uz variranje važnosti glavnih kriterija za 5 % u svim kombinacijama, možemo zaključiti da je rezultat stabilan.

Provedbom dinamičke analize osjetljivosti i varijacijom važnosti svih kriterija za 5% u svim kombinacijama, nije došlo do nikakve promjene u rangiranju alternativa, te zaključujemo da je dobiveni rezultat stabilan.


Slika 5-35. prikazuje jedan od scenarija u kojem je važnost kriterija „Formalno-pravna spremnost okruženja“ povećana za 5 % (na 36,8 %), te vidimo da je rang alternativa ostao isti, s malom promjenom u vrijednostima prioriteta alternativa. U odnosu na stanje prije promjene, alternativa „Hibridna ili mješovita nastava“ ima nešto malo veći prioritet koji sad iznosi 43%, alternativa „Nastava uz pomoć ICT“ ima nešto manji prioritet te on iznosi 32,1%, alternativa „Online obrazovanje“ ima veći prioritet te on iznosi 14,1 % i prioritet alternative „Klasična nastava“ ostaje nepromijenjen 10,8 % (Slika 5-35.).



Slika 5-35. Analiza osjetljivosti – opcija *Dynamic* iz čvora cilja, varijacija kriterija „Formalno-pravna spremnost okruženja“ za 5 %

Radi dodatne provjere, provedena je i dinamička analiza osjetljivosti u kojoj su varirane važnosti svih kriterija za 50% u svim kombinacijama, te možemo zaključiti da je najbolje rangirana alternativa „Hibridno učenje“ u svim kombinacijama i dalje najvećeg prioriteta, čime se dodatno potvrđuje stabilnost konačnog rezultata.

Na slici 5-36. prikazan je scenarij u kojem je važnost kriterija „Organizacijska i strateška spremnost okruženja“ povećana za 50 %, na 37,9 % i vidimo da je rang alternativa ostao isti, s time da je nešto smanjen prioritet najbolje rangirane alternative „Hibridno učenje“ na 42,3 %, prioritet alternative „Nastava uz pomoć ICT“ je povećan na 33,4 %, prioritet alternative „Online obrazovanje“ je smanjen na 13,3 % i prioritet alternative „Klasična nastava“ je nešto malo porastao na 11 %.



Slika 5-36. Analiza osjetljivosti – opcija *Dynamic* iz čvora cilja, varijacija kriterija „Organizacijska i strateška spremnost okruženja“ za 50 %

6. ANALITIČKI MREŽNI PROCES (ANP METODA)

Šesto poglavlje „Analitički mrežni proces“ sadržava metodološki i matematički opis ANP metode. Postoje određene razlike između AHP i ANP metode, pa je objašnjeno i argumentirano zašto se ANP metoda smatra dogradnjom AHP metode, napravljen je pregled primjena ANP metode te analiza mogućnosti njene primjene u rješavanju određenih problema. ANP model za rješavanje postavljenog problema je razvijen uz potporu alata *Super Decisions*, a testiranje modela je provedeno od strane eksperta domene na strateškom problemu odlučivanja o uvođenju e-učenja na visokoškolsku instituciju.

6.1. Temelji ANP metode

Metoda Analitički mrežni proces (ANP) je novija metoda za odlučivanje te uključuje određenu nadogradnju u odnosu na AHP metodu. ANP metoda omogućuje modeliranje funkcionalne interakcije kriterija i alternativa u modelu te se time postiže veća stabilnost rezultata. Metodološki i matematički temelji ANP metode opisani su u točkama 6.1.1. i 6.1.2.

Primjena ANP metode ima relativno malo u usporedbi s primjenama AHP-a i većina je napravljena u 2005. i 2006. godini. ANP metoda nije do sada primjenjivana za rješavanje strateških problema u domeni visokog školstva. Pregled primjena ANP metode nalazi se u točki 6.1.3.

6.1.1. Metodološki temelj ANP metode

ANP (engl. *Analytic Network Process*) metodu je razvio Thomas Saaty 1996. godine (Saaty, 1996/2001.). Struktura povratnih veza ili engl. «*feedback*» struktura koja postoji u ANP-u omogućuje mrežno definiranje problema te se razlikuje od AHP-a jer ne predstavlja linearnu hijerarhiju već modelira utjecaje između elemenata mreže. Mrežna zavisnost elemenata doprinosi boljem modeliranju realnih problema jer je većina problema iz realnog svijeta nelinearna, a povratne veze omogućuju preciznije određivanje prioriteta elemenata i donošenje kvalitetnijeg rješenja problema.


U hijerarhiji, važnosti (težine) kriterija služe kako bi se evaluirale (vrednovale) alternative i odredili njihovi prioriteti. Odluka se donosi na temelju postojećeg znanja. Može se reći da je takav pristup tzv. idealistički pristup odlučivanju. U mreži, svaka komponenta može zavisiti o

drugoj komponenti. Postavlja se pitanje koja od dvije alternative je dominantnija u odnosu na određeni kriterij, ali i pitanje koji od dva kriterija je dominantniji u odnosu na određenu alternativu (npr. Da li je određena osoba bolji nastavnik ili muzičar?). Takav pristup je tzv. pragmatičan pristup u donošenju odluka (Saaty, Katz predavanja, 2008.).


Slike 6-1. i 6-2. prikazuju razliku između hijerarhije i mreže. Hijerarhija je linearna «*top-down*» struktura koja sadrži cilj na vrhu hijerarhije, kriterije na prvoj razini, podkriterije na drugoj razini, alternative na trećoj razini hijerarhije i petlju koja indicira da svaki element ovisi sam o sebi (slika 6-1.). Mreža je tzv. «*feedback*» struktura (struktura povratne veze) koja sadrži komponente i elemente unutar komponenata, preciznije, klasterne i čvorove unutar klastera te petlje i lukove kojima se komponente mreže povezuju. Osnovni element mreže je klaster, a klasteri se sastoje od čvorova koji se međusobno povezuju ovisno o njihovoj zavisnosti. Razlikujemo ishodišne (engl. *source*) i odredišne (engl. *sink*) čvorove. Zavisnosti se prikazuju vezom (strelicom) između dva čvora između kojih postoji utjecaj. Strelica koja povezuje dva elementa označava utjecaj jednog elementa na drugi. Ishodišni čvor je onaj iz kojeg strelica izlazi i on utječe na odredišni čvor prema kojem je strelica usmjerena tj. odredišni čvor zavisi od ishodišnog čvora. Ukoliko čvorovi utječu međusobno jedan na drugog, takvu vezu nazivamo *feedback* vezom ili povratnom vezom. Mreža dopušta i modeliranje zavisnosti na način da jedan klaster utječe na drugi, a drugi utječe na prvi, ali ne direktno nego posredno preko trećeg tzv. prijelaznog klastera. Zavisnosti se modeliraju između čvorova, ali se radi jednostavnosti (na primjer u softveru *SuperDecisions*) prikazuju zavisnosti između klastera. U kreiranju ANP modela potrebno je izbjegavati tzv. *source* i *sink* komponente koje su isključivo ishodišne ili odredišne jer takva struktura nije prirodna i može dovesti do problema prilikom primjene AHP/ANP algoritma u izračunavanju prioriteta elemenata (Saaty, Katz predavanja, 2008.). Ako se vrši usporedba s AHP hijerarhijom, komponenta cilja je najbolji primjer ishodišne komponente. Cilj utječe na komponente niže razine, ali ni jedna komponenta ne utječe na njega.

Dvije su osnovne vrste zavisnosti između komponenata mreže: unutarnja i vanjska zavisnost (slika 6-2.). Ukoliko su čvorovi unutar klastera međusobno povezani («utječu jedan na drugog» u odnosu na neko svojstvo) govorimo o unutarnjoj zavisnosti unutar klastera i označavamo je petljom. Ukoliko su povezani čvorovi koji pripadaju različitim klasterima, govorimo o vanjskoj zavisnosti i označavamo je lukom između klastera. Nelinearna mreža je prikazana na slici 6-2. Ona sadrži klasterne i čvorove te unutarnje i vanjske zavisnosti između

elemenata (Saaty, 2005c, Saaty 2006.). Mreža se promatra i kao usmjereni graf, koji nije jednostavan jer sadrži petlje. Iz tog konteksta dolazi i navedena terminologija.



Slika 6-1. Linearna hijerarhija




Petlja (engl. *Loop*) u komponenti (kao u komponenti C₁, C₃) predstavlja unutarnju zavisnost elemenata te komponente u odnosu na određenu karakteristiku.

Slika 6-2. Mreža povratnih veza

Kao što je već napomenuto, odlučivanje ANP-om o određenim problemima daje preciznije rezultate nego odlučivanje AHP-om (Saaty, Katz predavanja, 2008.). Ključno je prepoznati kada je interakcija između elemenata neizostavna u modeliranju problema te tada odlučivanje temeljiti na ANP-u. Ono što je drugačije u ANP-u (u odnosu na AHP) je određivanje prioriteta elemenata mreže koji su u zavisnosti. Mreža sadrži lukove, a lukovi mogu biti neograničen, nedovršen proces zavisnosti između elemenata, pogotovo ako se radi o povratnoj vezi između elemenata. Određivanje prioriteta s obzirom na zavisnosti u mreži postaje zahtjevniji proces nego u AHP-u. Više o matematičkoj pozadini ANP-a u točki 6.1.2.

Osnovna razlika između AHP-a i ANP-a je da u AHP-u s obzirom na važnost kriterija određujemo prioritete alternativa, dok u ANP-u, uz to što kriteriji utječu na važnost alternativa, i važnost alternativa utječe na određivanje težina kriterija.

Primjerice, uspoređujemo dva mosta (dvije alternative) *Most A* i *Most B* te moramo odlučiti o njihovoj izgradnji na temelju dva kriterija: *Sigurnosti* i *Dizajna* (Saaty, 2006., SuperDecisions, 2006.). Oba mosta su sigurna, ali je *Most B* koji je sigurniji ujedno i lošijeg dizajna. Uspoređivanje kriterija i zatim uspoređivanje alternativa u odnosu na kriterije (postupak AHP-a) dovelo bi nas do odabira čvršćeg, ali lošije dizajniranog mosta tj. *Mosta B*, ali ukoliko evaluiramo i kriterije u odnosu na alternative (postupak ANP-a), alternativa većeg prioriteta postaje *Most A*. U ANP-u postavljamo sljedeće pitanje: «Ako gledamo *Most A* u klasteru *Alternative*, koji kriterij dominira, *Dizajn* ili *Sigurnost* i za koliko?» S obzirom da *Most A* zadovoljava kriterij *Sigurnosti*, a ujedno je i boljeg dizajna, jaka dominacija je na strani kriterija *Dizajn*. Ako postavimo isto pitanje za *Most B*, ekstremna dominacija će biti na strani kriterija *Sigurnost*. Sljedeći korak je uspoređivanje alternativa u odnosu na kriterije. U odnosu na kriterij *Dizajn*, *Most A* dominira nad *Mostom B* za 7 što na Saatijevoj skali relativne važnosti predstavlja vrlo strogu, dokazanu dominaciju. Ukoliko uspoređujemo alternative u odnosu na kriterij *Sigurnost*, *Most B* dominira nad *Mostom A*, ali s vrlo malom prednosti, jer je *Most A* također siguran. Sve to rezultira odabirom *Mosta A* kao alternative većeg prioriteta. Osnovni model s povratnom vezom prikazan je na slici 6-3. Procjene dane uspoređivanjem elemenata u parovima u skladu s povratnom vezom između komponenata *Alternative* i *Kriteriji* prikazane su na slici 6-4. Prioriteti kriterija i alternativa prikazani su na slici 6-5.



Slika 6-3. Povratna veza u ANP-u – primjer «Odabir mosta»

Graphic	Verbal	Matrix	Questionnaire																		
Comparisons wrt "Most A" node in "Kriteriji" cluster																					
Dizajn is strongly more important than Sigurnost																					
1. Dizajn	>=9.5	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	>=9.5	No comp.	Sigurnost
Comparisons wrt "Most B" node in "Kriteriji" cluster																					
Sigurnost is extremely more important than Dizajn																					
1. Dizajn	>=9.5	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	>=9.5	No comp.	Sigurnost
Comparisons wrt "Dizajn" node in "Alternative" cluster																					
Most A is very strongly more important than Most B																					
1. Most A	>=9.5	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	>=9.5	No comp.	Most B
Comparisons wrt "Sigurnost" node in "Alternative" cluster																					
Most B is equally to moderately more preferable than Most A																					
1. Most A	>=9.5	9	8	7	6	5	4	3	2	1	2	3	4	5	6	7	8	9	>=9.5	No comp.	Most B

Slika 6-4. Procjene dobivene uspoređivanjem elemenata u paru u skladu s povratnom vezom – primjer «Odabir mosta»

Name	Normalized by Cluster	Limiting
Most A	0.65691	0.328455
Most B	0.34309	0.171545
Dizajn	0.59737	0.298686
Sigurnost	0.40263	0.201314

Slika 6-5. Prioriteti kriterija i alternativa - primjer «Odabir mosta»

Tri su osnovne vrste supermatrica koje se formiraju u ANP-u:

1. **Neponderirana supermatrica** (engl. *Unweighted Supermatrix*) je matrica koja sadrži težine/prioritete dobivene uspoređivanjem elemenata u parovima u skladu sa zavisnostima između elemenata.
2. **Ponderirana supermatrica** (engl. *Weighted Supermatrix*) je matrica dobivena množenjem neponderirane supermatrice s težinama (prioritetima) klastera. Prioriteti klastera se prikazuju u **matrici klastera** (engl. *Cluster Matrix*), a dobiveni su uspoređivanjem klastera u parovima u skladu sa zavisnostima između klastera. Tim postupkom ponderirana supermatrica postaje stohastična (zbroy svakog stupca matrice jednak je 1). U hijerarhiji (AHP-u) ponderirana supermatrica je jednaka neponderiranoj supermatrici.
3. **Granična supermatrica** (*Limit supermatrix*) je matrica dobivena potenciranjem ponderirane supermatrice. Granična matrica se potencira tako dugo dok ne konvergira u odgovarajuću formu iz koje možemo iščitati prioritete elemenata (svi redovi matrice moraju biti jednaki). Postoje dvije vrste granične supermatrice: reducibilna i ireducibilna, odnosno granična matrica u kojoj zavisnosti nisu kružne i granična matrica u kojoj su zavisnosti kružne (npr. jedan element može utjecati na drugi element neposredno preko trećeg elementa). Ukoliko se radi o ireducibilnoj matrici tj. graničnoj matrici s kružnim zavisnostima, ona u postupku potenciranja ne konvergira u odgovarajuću formu, već se samo rotira i potrebno je koristiti Cesarovu sumu kako bi se izrazili prioritete elemenata.

Na primjeru odabira mosta možemo prikazati tri osnovne matrice: neponderiranu matricu, ponderiranu matricu (Tablica 6-1.) i graničnu matricu (Tablica 6-2.). U ovom primjeru radi se o povratnoj vezi između dvije komponente koja je beskonačna. S obzirom da je primjer jednostavan i model sadrži samo dva klastera Alternative i Kriterije koje ne uspoređujemo, neponderirana matrica nije množena s težinom klastera, pa je neponderirana matrica jednaka ponderiranoj matrici. Granična matrica dobivena je potenciranjem ponderirane matrice. Potenciranje je vršeno tako dugo dok matrica nije konvergirala u formu iz koje se daju iščitati prioritete elemenata (svi redovi matrice moraju biti jednaki). Ukoliko se potenciranjem matrice na k -tu potenciju, matrica ne konvergira već se samo rotira, tada se primjenjuje Cesarova suma kako bi se izračunali prioritete elemenata.

Tablica 6-1. Ponderirana matrica jednaka neponderiranoj matrici - primjer «Odabir mosta»

	Most A	Most B	Dizajn	Sigurnost
Most A	0.00000	0.00000	0.87500	0.33333
Most B	0.00000	0.00000	0.12500	0.66666
Dizajn	0.85714	0.09999	0.00000	0.00000
Sigurnost	0.14286	0.90001	0.00000	0.00000

Tablica 6-2. Granična matrica - primjer «Odabir mosta»

	Most A	Most B	Dizajn	Sigurnost
Most A	0.32846	0.32846	0.32846	0.32846
Most B	0.17155	0.17155	0.17155	0.17155
Dizajn	0.29869	0.29869	0.29869	0.29869
Sigurnost	0.20131	0.20131	0.20131	0.20131

Četiri su osnovna pitanja koja se postavljaju sudionicima tijekom provedbe procesa odlučivanja ANP metodom:

1. Koji od dva elementa ima veći utjecaj (dominantniji je) u odnosu na treći kriterij?
2. Koji od dva elemenata ima veći utjecaj (dominantniji je) u odnosu na određenu alternativu?
3. Ukoliko promatramo kriterij i element X u određenom klasteru, koji od dva elementa u istom klasteru ili u različitim klasterima ima veći utjecaj na element X u odnosu na taj kriterij?
4. Ukoliko promatramo kriterij i element X u određenom klasteru, na koji od dva elementa u istom klasteru ili u različitim klasterima, element X ima veći utjecaj u odnosu na taj kriterij?

ANP model se često koristi u određivanju tržišnog udjela i alokaciji resursa. U određivanju tržišnih udjela koristi se mreža u kojoj klaster Alternative sadrži imena kompanija za koje se nastoji odrediti tržišni udio. Nakon što se provede postupak ANP-a, moguće je usporediti preciznost dobivenih rezultata sa stvarnim tržišnim udjelima preko *Indeksa kompatibilnosti* koji mora biti veći od 1 da bi se rezultati smatrali korektnima (Saaty, 2005a, 2005b, 2005c). U alokaciji resursa, ANP se koristi kako bi se odredili prioriteti pri raspodjeli resursa. Koristi se u kombinaciji s programom *Excel (Solver)*, s ciljem preciznog definiranja iznosa resursa koji će se dodijeliti pojedinoj aktivnosti. Ukoliko koristimo AHP/ANP za odlučivanje o

određenom problemu vezano uz koristi, mogućnosti, troškove i rizike, primjenjujemo BOCR mrežu (engl. *Benefits, Opportunities, Costs, Risks*) i odlučivanje je subjektivnije, jer svaki donositelj odluke mora procijeniti što su za njega koristi, mogućnosti, troškovi i rizici vezano uz definirani problem. Ukoliko koristimo AHP/ANP za predviđanje rezultata odnosno posljedica naše odluke, primjenjujemo mrežu elemenata s kontrolnim kriterijima i odlučivanje je objektivnije.

Postoje tri osnovne razine ANP modela:

- 1) hijerarhija kombinirana s mrežom
- 2) mreža elemenata
- 3) BOCR (engl. *Benefits, Opportunities, Costs i Risks*) mreža elemenata s kontrolnim i strateškim kriterijima.

Model razvijen u okviru ove doktorske disertacije pripada drugoj razini modela: mreži elemenata s kontrolnim kriterijima (detaljnije u poglavlju 6.2.). Kako bi se detaljnije objasnio metodološki temelj ANP metode, u nastavku je opisano 12 osnovnih koraka ANP-a, na primjeru BOCR (engl. *Benefits, Opportunities, Costs i Risks*) modela koji je treća, najkompleksnija razina ANP modela. Opća struktura BOCR ANP modela prikazana je na slici 6-6. (Saaty, Katz, predavanja, 2008.).

Osnovni koraci u primjeni ANP metode (Saaty, 2005a, 2005b, 2005c):


1. Opisati detaljno problem odlučivanja. Definirati ciljeve, kriterije i podkriterije, sudionike i njihove ciljeve te moguće rezultate, posljedice određene odluke. Definirati utjecaje o kojima ovise posljedice određenih odluka. U hijerarhiji se elementi nazivaju kriterijima i podkriterijima, dok u mreži imamo klastere i čvorove unutar klastera.
2. Odrediti kontrolne kriterije i podkriterije u četiri kontrolne podmreže: koristi, mogućnosti, troškovi i rizici, BOCR (engl. *Benefits, Opportunities, Costs, Risks*) i uspoređivanjem u parovima odrediti prioritete kontrolnih kriterija. Ukoliko kontrolni kriterij ili podkriterij ima globalni prioritet od 3% ili manje, može ga se isključiti iz daljnjih razmatranja. Softver *SuperDecisions* automatski nastavlja proceduru samo s kontrolnim kriterijima i podkriterijima koji imaju podmrežu. Kod uspoređivanja elemenata u parovima u odnosu na koristi i mogućnosti, postavlja se pitanje što će dati veću korist ili predstavlja veću mogućnost u ispunjenju određenog kontrolnog kriterija. Za troškove i rizike, postavlja se pitanje što je rizičnije ili skuplje u odnosu na

ispunjenje kontrolnog kriterija. Kontrolni kriteriji se nalaze na drugoj razini u podmreži (npr. podmreži koristi), a uobičajeni kontrolni kriteriji su: politički, socijalni, ekonomski i dr.

3. Odrediti mrežu klastera i njihovih čvorova u skladu s kontrolnim kriterijima. Prilikom kreiranja modela, potrebno je numerirati klastera i čvorove radi kasnije lakše obrade rezultata. Vrlo je važno da se koriste potpuno ista imena za klastera i čvorove koji se ponavljaju odnosno koji su identični u više od jedne kontrolne hijerarhije.
4. Odrediti zavisnosti, utjecaje između elemenata u modelu. Zavisnost elemenata (čvorova) unutar klastera naziva se unutarnja zavisnost dok se zavisnost elemenata jednog klastera o elementima drugog klastera naziva vanjska zavisnost.
5. Za svaki kontrolni kriterij, kontrolnu hijerarhiju, kreirati supermatricu na temelju usporedbi u parovima za određene elemente (čvorove) koji međusobno zavise u toj kontrolnoj hijerarhiji. Potrebno je provesti komparaciju u parovima za sve unutarnje i vanjske zavisnosti elemenata u hijerarhiji. Rezultat je **neponderirana matrica** koja sadrži prioritete elemenata dobivene uspoređivanjem elemenata u parovima.
6. Provesti usporedbu klastera u parovima u skladu s njihovom zavisnosti, a u odnosu na kontrolne kriterije. Dobiveni prioritete služe kako bi se njima pomnožili elementi supermatrice dobiveni u 5. koraku. Određeni blokovi elemenata se množe s prioriteteom pripadajućeg klastera. Gdje nema utjecaja upisujemo 0. Opisanim postupkom dobivamo **stohastičku ili tzv. ponderiranu supermatricu** za koju vrijedi da je zbroj elemenata svakog njenog stupca jednak 1.
7. Izračunati elemente granične supermatrice. **Granična supermatrica** je matrica dobivena potenciranjem ponderirane supermatrice. Postoje dvije vrste granične supermatrice: granična matrica u kojoj zavisnosti nisu kružne i granična matrica u kojoj su zavisnost kružne (npr. jedan element može utjecati na drugi element posredno preko trećeg elementa). U graničnoj supermatrici u kojoj zavisnosti nisu kružne, elementi svih kolona su identični i predstavljaju relativne prioritete elemenata. Ukoliko se radi o drugoj vrsti granične matrice, tada se u izračunu koristi Cesarova suma kako bi se u prioritete uključile sve postojeće zavisnosti. Granični prioritete se zbrajaju i izračunava se njihov prosjek te se vrši normalizacija.
8. Izvršiti sintezu prioriteta iz granične supermatrice na način da se dobiveni prioritete množe s težinom kontrolnih kriterija i sintetiziraju s prioriteteom koristi, mogućnosti, troškova i rizika. Da bi se dobili prioritete BOCR-a, trebaju se generirati strateški kriteriji. Strateške kriterije možemo izjednačiti s našim osobnim vrijednostima.

Određuju se njihovi prioriteti uspoređivanjem u parovima. Nakon što se dobiju alternative s najvišim prioritetima u odnosu na B, O, C i R, uzimaju se top alternative za svaku od pod mreža i vrednuju se u odnosu na strateške kriterije. Sintezom dobivenih procjena, dobivamo prioritete za koristi, mogućnosti, troškove i rizike.

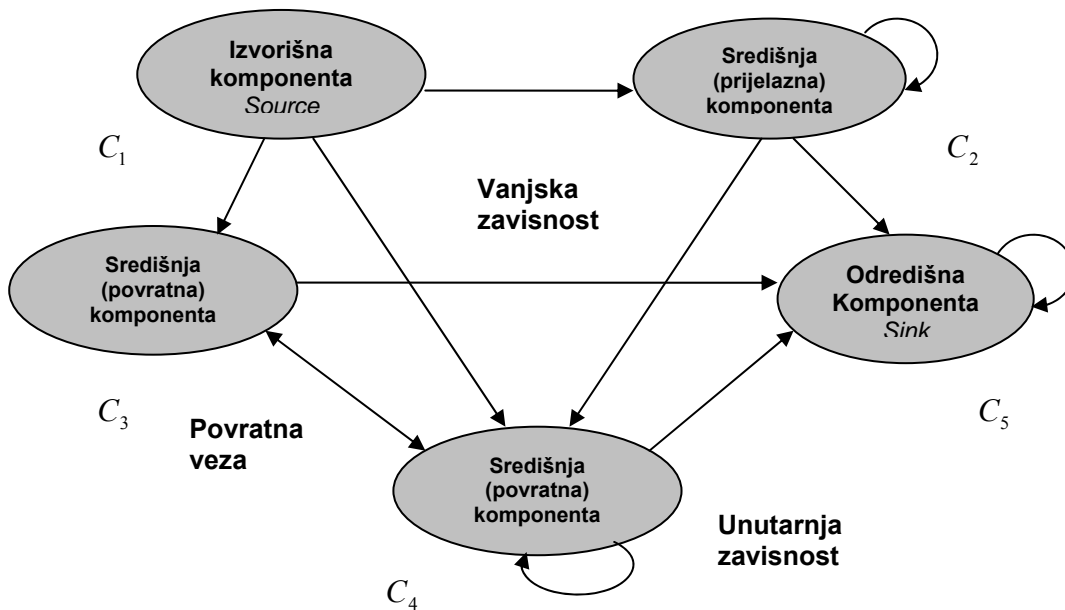
9. Da bismo dobili alternativu koja se preferira u odnosu na sve četiri BOCR pod mreže, možemo koristiti multiplikativnu (engl. *multiplicative*) ili aditivnu (engl. *additive*) formulu. Multiplikativna formula množi vektore prioriteta za koristi i mogućnosti i zatim ih dijeli s umnoškom troškova i rizika (BO/CR). Aditivna formula glasi $bB + oO - cC - rR$ u kojoj su b, o, c i r prioriteti dobiveni vrednovanjem top alternativa u odnosu na strateške kriterije, a B, O, C i R su vektori prioriteta alternativa dobiveni u pod mrežama. Precizniji rezultati se dobiju primjenom aditivne formule.
10. Obraditi rezultate i analizirati osjetljivost.



Slika 6-6. Struktura BOCR ANP modela

6.1.2. Matematički temelj ANP metode

Da bi se lakše objasnili matematička pozadina ANP-a, odnosno postupak izračunavanja prioriteta elemenata, potrebno je prvo prikazati i objasniti tipove komponenata u ANP mreži, te zatim postupak izračunavanja matrica i finalnih prioriteta elemenata. Tipovi komponenata u ANP mreži prikazani su na slici 6-7. (Saaty, 2005c, Saaty & Vargas, 2006.).



Slika 6-7. Tipovi komponenata u ANP mreži

Komponente koje nemaju ulaznih veza (ulaznih strelica) nazivaju se izvorišne komponente (engl. *source component*). Primjer izvorišne komponente je komponenta C_1 . Komponente koje nemaju izlaznih veza (izlaznih strelica) nazivaju se odredišne komponente (engl. *sink component*). Primjer odredišne komponente je komponenta C_5 . Komponente koje imaju i ulazne i izlazne veze nazivaju se središnjim komponentama (engl. *intermediate component*). Primjeri središnjih komponenata su C_2 , C_3 i C_4 . Komponenta C_2 je prijelazna komponenta, dok su C_3 i C_4 komponente između kojih postoji povratna veza. Komponente C_2 i C_4 imaju petlje koje ih povezuju sa samim sobom i označavaju njihovu unutarnju zavisnost. Sve ostale veze predstavljaju vanjsku zavisnost (slika 6-7.).

Komponente mreže odlučivanja označimo sa C_h , $h=1, \dots, n$. Pretpostavimo da komponenta h ima n_h elemenata što označavamo sa $e_{h1}, e_{h2}, \dots, e_{hn_h}$ (slika 6-8.). Utjecaj elemenata komponente na bilo koji drugi element u sustavu, prikazan je preko vektora težine (prioriteta) koji je dobiven istim principom kao u AHP-u. Matematički temelj AHP-a, postupak uspoređivanja u parovima odnosno davanja procjena i izračunavanja vektora težina (prioriteta elemenata) objašnjen je u poglavlju 5.1.2. Pitanje je kako izvršiti sintezu prioriteta elemenata i unutarnjih i vanjskih zavisnosti između komponenata u ANP-u.

Tipičan element u supermatrici (slika 6-8.) je blok supermatrice W_{ij} . Forma bloka supermatrice prikazana je na slici 6-9. Svaki stupac bloka supermatrice je vektor vlastite vrijednosti koji predstavlja utjecaj (važnost) elementa u i -toj komponenti mreže na element u j -toj komponenti mreže. Neki ulazi u bloku supermatrice mogu biti 0 što znači da ti elementi nemaju zavisnosti. Kada vršimo procjene da bismo dobili vektore vlastite vrijednosti, ne moramo vršiti komparacije svih elemenata već samo onih koji su u međusobnoj zavisnosti.

Slike 6-10. i 6-11. predstavljaju hijerarhiju i holarhiju i njihove pripadajuće supermatrice od m razina. Kao i u svakoj supermatrici, osnovni element je blok W_{ij} pozicioniran na mjestu gdje je i -ta razina (lijeva strana matrice) povezana i utječe na j -tu razinu (vrh matrice). Ulaz u zadnjem redu i koloni supermatrice hijerarhije je jedinična matrica I . Ona korespondira luku u donjoj razini hijerarhije i označava da svaki element ovisi samo o sebi. Uspoređujući sa slikom holarhije, ulaz u prvom redu i zadnjoj koloni matrice nije 0, jer top razina holarhije zavisi od donje (najniže) razine.

Da bi se iz supermatrice u kojoj je suma kolone obično veća od 1 dobili tzv. granični prioriteti utjecaja elemenata, supermatrica se prvo treba transformirati u tzv. stohastičnu matricu za koju vrijedi da je suma elemenata svakog njenog stupca jednaka 1. Komponente se kompariraju u skladu s postojećom zavisnosti i u odnosu na kontrolni kriterij više razine. Na taj način se dobivaju vektori težina koji uključuju utjecaje svih komponenata na lijevoj strani supermatrice na komponente na vrhu matrice. Postupak se ponavlja onoliko puta koliko ima komponenata. Dobiveni vektori težina služe kako bi se njime pomnožili blokovi matrice u određenoj koloni pod određenom komponentom. Rezultat opisanog postupka je tzv. ponderirana matrica koja je stohastična.

Komponenta C_1 u supermatrici uključuje sve vektore prioritete za čvorove koji su tzv. čvorovi roditelji u C_1 klasteru. Slika 6-10. prikazuje supermatricu hijerarhije koja je već stohastična i njeni klasteri imaju jednake težine. Iz tog razloga, svi blokovi matrice su množeni s istim brojem. Slika 6-12. prikazuje k -tu potenciju te supermatrice koja je ista kao i hijerarhijska kompozicija u (k, I) poziciji/mjestu.

Sljedeći korak je izračunavanje granične matrice. Temeljno pitanje u ANP-u je kako integrirati sve postojeće tranzitivnosti u finalne prioritete elemenata. U rješavanju tog pitanja,

koristi se teorem koji kaže da se utjecaji (zavisnosti) između elemenata matrice mogu sačuvati na način da se matrica potencira na k -tu potenciju s time da je k staza odnosno put zavisnosti između elemenata matrice. Već je napomenuto da zavisnosti mogu biti “kružne” i različitih staza i duljina. Jedan element može utjecati na drugi preko više elemenata pa vezano uz strukturu matrice i zavisnosti elemenata ovisi koliko puta ćemo potencirati matricu odnosno koliki će biti k . Ukoliko je matrica reducibilna, nakon njenog potenciranja k puta, dobivamo traženu strukturu. Ukoliko je ireducibilna, koristimo Cesarovu sumu kako bi se odredili prioriteta za sve tranzitivnosti različitih duljina.

Ukupnu dominaciju $w(A_i)$, alternative A_i na ostale alternative preko puteva različitih duljina, možemo prikazati na sljedeći način (beskonačan niz):

$$w(A_i) = \sum_{k=1}^{\infty} \frac{\sum_{j=1}^n a_{ij}^{(k)}}{\sum_{i=1}^n \sum_{j=1}^n a_{ij}^{(k)}}$$

čija suma je Cesarova suma:

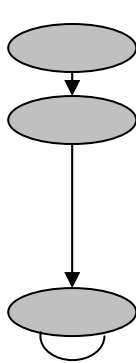
$$\lim_{M \rightarrow \infty} \frac{1}{M} \sum_{k=1}^M \frac{\sum_{j=1}^n a_{ij}^{(k)}}{\sum_{i=1}^n \sum_{j=1}^n a_{ij}^{(k)}}$$

$$W = \begin{matrix} & \begin{matrix} C_1 & & C_2 & \dots & C_N \\ e_{11}e_{12}\dots e_{1n_1} & e_{21}e_{22}\dots e_{2n_2} & e_{N1}e_{N2}\dots e_{Nn_N} \end{matrix} \\ \begin{matrix} C_1 \\ \vdots \\ C_2 \\ \vdots \\ C_N \end{matrix} & \begin{bmatrix} W_{11} & W_{12} & \dots & W_{1N} \\ W_{21} & W_{22} & \dots & W_{2N} \\ \vdots & \vdots & \dots & \vdots \\ W_{N1} & W_{N2} & \dots & W_{NN} \end{bmatrix} \end{matrix}$$

Slika 6-8. Supermatrica mreže


$$W_{ij} = \begin{bmatrix} W_{i1}^{(j_1)} & W_{i1}^{(j_2)} & \dots & W_{i1}^{(j_{n_j})} \\ W_{i2}^{(j_1)} & W_{i2}^{(j_2)} & \dots & W_{i2}^{(j_{n_j})} \\ \vdots & \vdots & \dots & \vdots \\ W_{in_i}^{(j_1)} & W_{in_i}^{(j_2)} & \dots & W_{in_i}^{(j_{n_j})} \end{bmatrix}$$

Slika 6-9. Blok (komponenta) supermatrice



$$W = \begin{bmatrix} 0 & 0 & 0 & \dots & \bullet & 0 & 0 \\ W_{21} & 0 & 0 & \dots & \bullet & 0 & 0 \\ 0 & W_{32} & 0 & \dots & \bullet & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \bullet & \bullet & \bullet & \dots & W_{n-1,n-2} & \bullet & \bullet \\ 0 & 0 & 0 & \dots & \bullet & W_{n,n-1} & I \end{bmatrix}$$

Slika 6-10. Supermatrica hijerarhije



Slika 6-11. Supermatrica holarhije

$$W^k = \begin{bmatrix} 0 & 0 & 0 & \dots & 0 & 0 & 0 \\ 0 & 0 & 0 & \dots & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \dots & 0 & 0 & 0 \\ W_{n,n-1}W_{n-1,n-2} \dots W_{32}W_{21} & W_{n,n-1}W_{n-1,n-2} \dots W_{32} & \dots & W_{n,n-1}W_{n-1,n-2} & W_{n,n-1} & I \end{bmatrix}$$

Slika 6-12. Granična matrica hijerarhije

Matematički temelji AHP i ANP metode detaljno su objašnjeni u posebnom izdanju časopisa *Mathematical and Computer Modelling* (Volume 46, Issues 7-8, October 2007) posvećenom AHP i ANP metodi. Thomas Saaty (Saaty, 2007.) je u tom izdanju objavio članak o dinamičnim prioritetima u AHP/ANP-u odnosno o primjeni AHP i ANP metode u rješavanju kompleksnih problema i donošenju dinamičnih odluka. U članku su objašnjena tri načina primjene AHP/ANP metode u dinamičnom donošenju odluka te su navedeni primjeri (Saaty, 2007.). Rozann Whitaker (Whitaker, 2007.) je u članku «Validation examples of the Analytic Hierarchy Process and Analytic Network Process» navela niz načina i primjera validacije razvijenih i primjenjenih AHP i ANP modela u rješavanju realnih problema. Uspoređeni su rezultati dobiveni AHP i ANP metodom sa stvarnim rezultatima te je objašnjen indeks kompatibilnosti koji služi u mjerenju blizine vektora prioriteta odnosno u provjeri preciznosti rezultata predviđanja AHP/ANP metodom. Wijnmalen (Wijnmalen, 2007.) je

napravio kritičku analizu BOCR pristupa (B-koristi, O-mogućnosti, C-troškovi, R-rizici) u AHP/ANP metodi. Pokazao je da je multiplikativna i aditivna sinteza prioriteta za B-koristi, O- mogućnosti, C-troškovi, R-rizici u AHP/ANP metodi ponekad preambiciozna. Koristio je primjer procjenjivanja profitabilnosti projekta primjenom AHP/ANP metode. Rozann Whitaker je u svom članku (Whitaker, 2007.) argumentirala zašto određene kritike AHP/ANP metode nemaju smisla. U članku je prezentirano nekoliko primjera krivog modeliranja AHP/ANP metodom te je objašnjeno kako pri modeliranju nisu poštivani osnovni uvjeti modeliranja koje zadaje AHP/ANP metoda. Ti primjeri su promijenjeni u skladu s uvjetima modeliranja AHP/ANP metodom te je pokazano kako su AHP/ANP modeli nakon promjena dali očekivane rezultate. Cilj članka Claudia Garutia i Isabelle Spencer (Garuti & Spencer, 2007.) bio je prikazati paralelizme i analogizme koji postoje u modeliranju i mjerenju zavisnosti i povratnih veza u fizičkim procesima i procesima donošenja odluke, odnosno usporedba između mjernih skala u fizičkom svijetu (geometrija) i mjernih skala u ljudskom procesu donošenja odluka. U članku Thomasa Saatyja, Kirti Peniwati i Jen S. Shang (Saaty, Peniwati & Shang, 2007.) prikazano je kako primijeniti apsolutnu skalu u AHP-u zajedno s linearnim programiranjem s ciljem optimiziranja problema alokacije ljudskih resursa.

6.1.2.1. Razlika između AHP i ANP metode

Suštinska razlika između metoda AHP i ANP je ta da je ANP metoda nadogradnja AHP metode. Ta nadogradnja sastoji se u tome što metoda ANP omogućuje modeliranje kompleksnosti koja proizlazi iz povratnih veza između strukturnih elemenata problema odlučivanja. Umjesto jednostavnog, linearnog hijerarhijskog modela problema odlučivanja koji je temelj za AHP metodu, u modeliranju problema koji se rješava ANP metodom razvija se mrežna struktura. Prioriteti alternativa i težine kriterija i u metodi ANP se interpretiraju kao vrijednosti komponenata svojstvenih vektora odgovarajuće tzv. supermatrice. Iako ova matrica ima svojstva koja i dalje osiguravaju mogućnost primjene osnovnih matematičkih rezultata na kojima se temelji povezivanje prioriteta alternative i težina kriterija s komponentama svojstvenog vektora koji pripada najvećoj svojstvenoj vrijednosti te matrice, te težine i najveća svojstvena vrijednost ne mogu se računati na isti način kao u AHP metodi.

Iako su AHP i ANP metode detaljno prikazane u poglavlju 5. i 6. ove disertacije, za potrebe razumijevanja matematičke osnove ANP metode ukratko će se nabrojati koraci u njezinoj standardnoj primjeni na takav način da se najlakše uoči razlika između tih dviju metoda:

Korak 1: Razvije se model problema odlučivanja koji sadrži sve bitne elemente koji omogućuju modeliranje zavisnosti i povratnih veza.

Korak 2: Uz pomoć Saaty-eve skale procjenjuju se vrijednosti omjera relativnih važnosti elemenata strukture mrežnog modela.

Korak 3: Na temelju procjena donesenih u prethodnom koraku računaju se lokalni prioriteti i konzistencija tih procjena po postupku sukladnom onom u AHP metodi.

Korak 4: Formira se početna supermatrica. Ona može imati različitu strukturu koja bitno utječe na postupak računanja konačnih prioriteta i težina elemenata problema odlučivanja. Razlike u postupku računanja direktna su posljedica oblika ovisnosti u strukturi modela odlučivanja, preciznije, o tome da li postoji potreba da se modelira povratna veza alternativa i kriterija (da li na važnost kriterija utječe to koja se alternative analizira). Ukoliko ova supermatrica nije stohastička, to svojstvo se postiže normalizacijom njezinih stupaca (dijeljenjem svakog njezinog elementa zbrojem stupca kojem on pripada).

Korak 5: Normalizirana supermatrica se potencira tako dugo dok ne konvergira u graničnu vrijednost. Tu može doći do problema jer stohastičke matrice kakve se javljaju u ANP mrežnim modelima ne moraju imati jedinstven limes. Egzistencija jedinstvenog limesa ANP stohastičke supermatrice direktna je posljedica činjenice postoji li ili ne cikličnost u njoj (u nekom od njezinih klastera). Ovdje razlikujemo dva slučaja: slučaj 1 kada nema cikličnosti i slučaj 2 kada postoji cikličnost u supermatrici.

Slučaj 1 - nema cikličnosti:

Računa se $\lim_{k \rightarrow \infty} W^k$, stupci ove matrice su jednaki i sadrže komponente svojstvenog vektora koji pripada najvećoj svojstvenoj vrijednosti supermatrice i te vrijednosti interpretiraju se kao prioriteti i težine elemenata problema odlučivanja.

Slučaj 2 – postoji cikličnost u supermatrici

U ovom slučaju granična vrijednost $\lim_{k \rightarrow \infty} W^k$ nije jedinstvena. Mogu postojati dvije ili više graničnih matrica pa se za težine i prioritete uzimaju vrijednosti stupca matrice koja se izračuna kao njihova Cesarova suma $\lim_{k \rightarrow \infty} \frac{1}{N} \sum_{j=1}^N W_j^k$ (elementi ove matrice računaju se kao prosječne vrijednosti matrica koje se pojavljuju kao granične vrijednosti od $\lim_{k \rightarrow \infty} W^k$).

6.1.3. Pregled primjena ANP metode

Praktičnih primjena ANP-a nema toliko mnogo ukoliko radimo usporedbu s AHP-om. Prvi razlog je taj što je ANP relativno nova metoda, drugi razlog je jednostavnost kreiranja hijerarhije i primjene AHP-a, a treći razlog je nepostojanje adekvatnog softvera koji bi omogućio primjenu ANP-a u rješavanju problema strateške važnosti.

Jedini pregled literature o ANP metodi napravio je profesor Enrique Mu s Carlow sveučilišta u Pittburghu u SAD-u. U svom pozvanom predavanju na godišnjem sastanku INFORMS-a 2006. godine (Mu, 2006.), prezentirao je statističke podatke o primjeni AHP i ANP metode u prvih 10 godina njihova postojanja, za AHP metodu u razdoblju od 1980. – 1990. godine, a za ANP metodu od 1996. – 2006. godine. U svojem istraživanju, profesor Mu je koristio sljedeće izvore: Google Scholar, INSPEC, izdane knjige ili knjige u printu, doktorske disertacije u elektroničkom formatu i kombinaciju 107 baza podataka s pristupom sa sveučilišne knjižnice Sveučilišta u Pittburghu.

Pretraživajući *Google Scholar* s ključnom frazom “*Analytic Network Process*” dobiven je 301 rezultat za razoblje od 1996. - 2006. godine i 462 rezultata kada se period nije specificirao. Autori s najviše rezultata bili su: Saaty, T.L., Vargas, L., Meade, L., Lee, J. i Salo, A. Primjenom ključne fraze “*Analytic Hierarchy Process*”, pronađeno je 416 rezultata za period od 1980. - 1990. godine, a 10 300 rezultata kada se period nije specificirao. Autori s najviše publikacija su: Saaty, T.L., Vargas, L., Harker, P. i Dyer J.

Pregled broja publikacija ANP metode, prema autorima publikacija, nalazi se u tablici 6-3. (Mu, 2006.). Radi usporedbe je u tablici 6-4. prikazan i pregled broja publikacija AHP metode (≥ 3) prema autorima publikacija.

Tablica 6-3. Broj publikacija (≥ 3) ANP metode prema autorima u razdoblju od 1996. – 2006. godine

Autor	Broj publikacija	Sveučilište
Meade, L.M.	5	Dallas Univ.,TX, USA
Saaty, T.L.	4	Univ. of Pitt., PA, USA
Presley, A.	4	Truman State U., MO, USA
Tiwari, M.K.	3	GET, Tata Motors, India
Heng, Li	3	Virginia U., VA, USA
Kahraman, C.	3	Istanbul Tech. U., Turkey
Leung, L.C.	3	Chinese U., Hong Kong
Buyukozkan, G.	3	Galatasaray U., Turkey
Ertay, T.	3	Istanbul Tech. U., Turkey

Tablica 6-4. Broj publikacija (≥ 3) AHP metode prema autorima u razdoblju od 1980. – 1990. godine

Autor	Broj publikacija	Sveučilište
Saaty, T.L.	31	Univ. of Pitt., PA, USA
Korpela, J.	14	Kymmene Corp., Finland
Tuominen, M.	13	Lappeenranta Univ., Finland
Liberatore, M.J.	12	Villanova Univ., PA, USA
Kahraman, C.	11	Istanbul Tech, U., Turkey
Vargas, L.G.	11	Univ. of Pitt., PA, USA
Arbel, A.	11	Tel-Aviv Univ., Israel
Chan, F.T.S.	10	Hong Kong U., Hong Kong

Pregled broja publikacija ANP metode (≥ 3) prema zemlji objave, nalazi se u tablici 6-5. Radi usporedbe prikazan je i pregled broja publikacija AHP metode (≥ 3) prema zemlji objave u tablici 6-6. Pregled radova rađen je u bazi INSPEC.

Tablica 6-5. Broj publikacija (≥ 3) ANP metode prema zemlji objave u razdoblju od 1996. – 2006. godine

Zemlja	Broj publikacija
SAD	19
Kina	15
Turska	9
Japan	6
Taiwan	6
Indija	3

Tablica 6-6. Broj publikacija (≥ 3) AHP metode prema zemlji objave u razdoblju od 1980. – 1990. godine

Zemlja	Br. publikacija	Zemlja	Br. publikacija	Zemlja	Br. publikacija
SAD	384	Vel. Brit.	61	Indija	38
Kina	314	Kanada	44	Finska	33
Japan	110	Koreja	43	Španjolska	20
Taiwan	74	Turska	38	Australija	18

Tablica 6-7. prikazuje usporedbu broja publikacija AHP i ANP metode u prvih 10 godina postojanja metoda. Općenito je mnogo više publikacija AHP metode od ANP metode. Međutim, broj objavljenih knjiga i knjiga u printu o ANP-u (u razdoblju od 1996. – 2006.), je za 12% veći nego broj knjiga objavljenih o AHP-u (u razdoblju od 1980. – 1990.). Broj doktorskih disertacija o AHP-u (44) je za 93% veći od broja doktorskih disertacija o ANP-u (3). Detaljan prikaz nalazi se u tablici 6-7.

Tablica 6-7. Usporedba broja publikacija AHP i ANP metode u prvih 10 godina postojanja metoda

	1980 - 1990	1996 - 2006	Razlika	Period nije određen	
	AHP	ANP		AHP	ANP
Članci i knjige					
Google Scholar	416	301	-28%	10.300	462
Članci					
INSPEC	156	74	-53%	1.404	74
Knjige					
Knjige u printu	5	11	120%	29	11
Amazon	26	29	12%	501	29
Doktorske disertacije					
Disertacije u elektroničkom formatu	44	3	-93%	219	3

Primjene ANP-a u znanstvenim radovima su različite. Neke od primjena ANP-a u radovima objavljenim u znanstvenim časopisima su sljedeće: vrednovanje dobavljača primjenom ANP metode (Meade, 1998., Agarwal & Shankar, 2003., Bayazit, 2006.), odabir projekata (Meade, 2002., Mohanty, 2005., Cheng, 2005a), odabir lokacije (Cheng, 2005b), evaluacija alternativnih oblika goriva (Ergdogmus, 2006.), analiza ekonomskih elemenata u današnjoj ekonomiji (Fiala, 2005.), dizajniranje logističkog centra za e-poslovanje (Hui, 2003.), planiranje proizvoda u QFD (Quality Function Deployment) primjenom ANP-a (Karsak, 2002.), primjena BSC-a (Balanced Scorecarda) uz pomoć AHP i ANP metode (Leung, 2006.), rješavanje konflikata (Su, 2005.), analiza održivosti sustava uređivanja šuma (Wolfslehner, 2005.), odabir partnera za usavršavanje osoblja (Chen, 2004., Chen, 2006.) i dr.

Objavljeno je i više knjiga na temu Analitičkog mrežnog procesa (Saaty, 2001., Saaty & Ozdemir 2005a, Saaty 2005b, 2005c, Saaty & Vargas, 2006., Saaty & Cillo, 2008.) od kojih primjere primjene ANP-a najbolje ocrtavaju knjige Encyclicon 1 (Saaty & Ozdemir, 2005a) i Encyclicon 2 (Saaty & Cillo, 2008.). One su tzv. rječnik odluka koje sadrže stotine primjera mrežnog modeliranja problema (ANP-a) u poslovanju, politici, obrazovanju, zdravstvu i medicini, kriminalu, vojsci, industriji i proizvodnji i dr. ANP modeli su kreirani od strane konzultanata, eksperata te studenata na poslovnoj školi Katz Graduate School of Business (Katz Graduate School of Business, UniPitt), a temeljeni su na njihovom iskustvu i stečenom znanju u praksi.

U Hrvatskoj nije objavljivano na temu Analitičkog Mrežnog Procesa, što znači da ne postoji literatura na hrvatskom jeziku koja bi pokrivala područje ANP-a. Napravljeno je i pretraživanje baze SCI-EXPANDED (Science Citation Index Expanded™) (pretraživanje po ključnim riječima ANP i/ili Analytic Network Process) kako bi se utvrdio broj radova koji na neki način dotiču temu ANP-a, a koje su objavili autori iz Hrvatske u priznatim međunarodnim znanstvenim časopisima, međutim broj pronađenih rezultata je jednak nuli.

6.2. ANP model za donošenje odluke o uvođenju e-učenja u visoko školstvo

ANP model za višekriterijsko odlučivanje o obliku uvođenja e-učenja u visoko školstvo, razvijen je na temelju reduciranog skupa kriterija i složenih interakcija između kriterija i alternativa odlučivanja. Testiranje modela provedeno je odlučivanjem o problemu uvođenja e-učenja na razini institucije koje je provedeno od strane eksperta domene uz potporu ANP modela. U razvoju i testiranju modela koristio se alat *SuperDecisions* (SuperDecisions, 2006.).

Razvojem i testiranjem ANP modela, potvrđena je treća hipoteza koja glasi:

H3: Kod donošenja odluka u procesu strateškog planiranja uvođenja e-učenja na razini sveučilišta i fakulteta, pojavljuju se složene interakcije između kriterija za odlučivanje i one se mogu modelirati pomoću analitičkog mrežnog procesa.

Postupak razvoja ANP modela te testiranje modela i rezultati odlučivanja eksperta domene ANP metodom uz potporu alata *SuperDecisions*, prikazani su u poglavlju 6.2.

6.2.1. Razvoj ANP modela odlučivanja

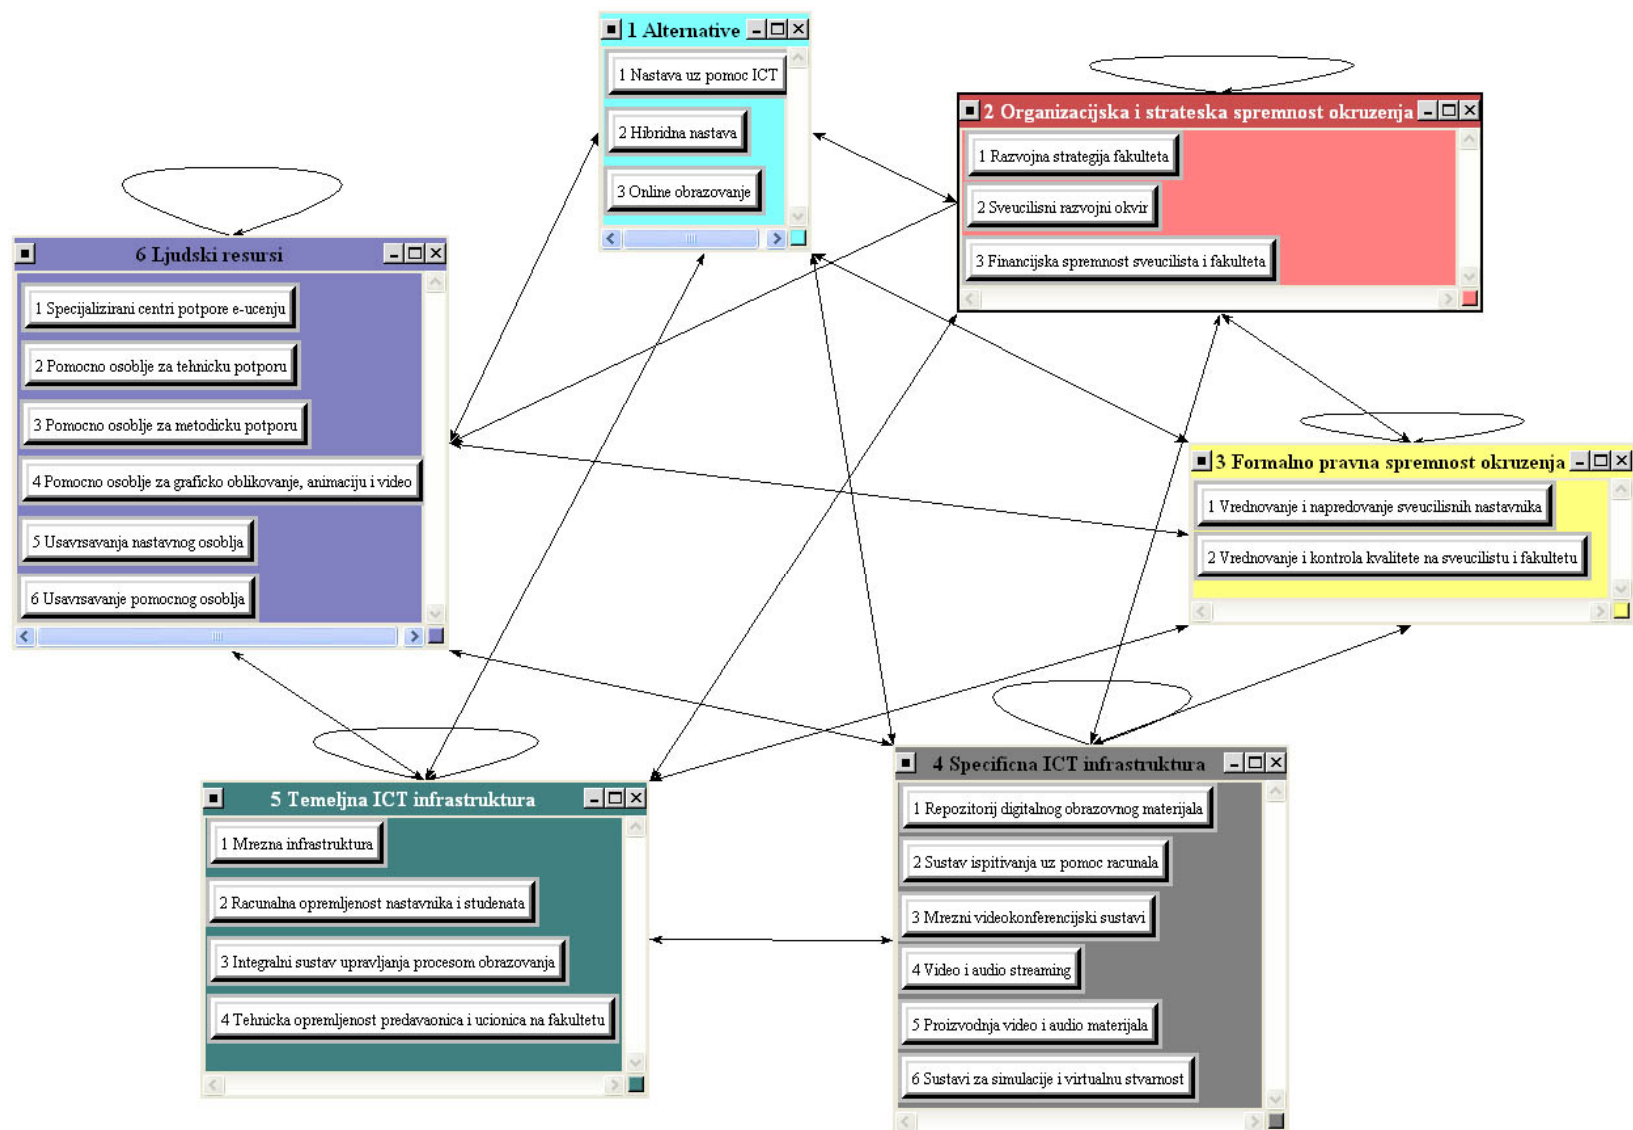
Ciljevi razvoja ANP modela za donošenje odluke o uvođenju e-učenja u visoko školstvo bili su pomoć u izradi strategije e-učenja Sveučilišta u Zagrebu i strategije e-učenja Fakulteta organizacije i informatike te potpora odlučivanju o obliku uvođenju e-učenja na razini visokoškolske institucije.

Primjenom kombinirane metode opisane u poglavlju 4., definirani su kriteriji i podkriteriji ključni za uspješnu implementaciju e-učenja na sveučilišnoj i fakultetskoj razini. Input u mrežnu strukturu ANP modela bili su „pročišćeni“ kriteriji koji su izdvojeni postupkom faktorske analize i alternative definirane pregledom znanstvene i stručne literature.

Objašnjenje značenja čvorova (podkriterija) nalazi se u poglavlju 5.2.1. Klaster Alternative u ANP modelu sadrži tri čvora, odnosno tri alternative: Nastava uz pomoć ICT, Hibridna nastava i Online obrazovanje. Alternativa Klasična nastava nije uvrštena u ANP model s obzirom da ANP model služi kao potpora izradi strategije e-učenja na institucijskoj razini, te je logično da se alternativa Klasična nastava ne razmatra kao jedna od potencijalnih alternativa e-učenja.

Mrežna struktura ANP modela kompleksnija je i zahtjevnija od hijerarhijske strukture AHP-a jer uzima u obzir razne forme zavisnosti i povratne veze između kriterija i alternativa te na taj način bolje ocrta problem odlučivanja u stvarnim uvjetima. Struktura povratnih veza ili tzv. «*feedback*» struktura ANP-a omogućuje mrežno definiranje problema i modeliranje utjecaja između elemenata mreže. Odlučivanje primjenom ANP metode je kompleksnije u odnosu na AHP metodu, rezultira stabilnijim rješenjem, ali zahtjeva bolje razumijevanje metode i problema te više vremena i koncentracije prilikom evaluacije modela. To je razlog zašto je ANP model primijenjen za odlučivanje o uvođenju e-učenja na strateškim razinama fakulteta i sveučilišta te kao pomoć u izradi strategije e-učenja Sveučilišta u Zagrebu i Fakulteta organizacije i informatike.

ANP model razvijen je na temelju reduciranog skupa kriterija i složenih interakcija između kriterija odlučivanja. Zavisnosti i povratne veze između čvorova i klastera (kriterija, podkriterija i alternativa) u ANP modelu, postavljene su temeljem znanja prikupljenog pregledom literature, a evaluirane su od strane eksperata domene, članova Jezgre za međunarodne projekte na Fakultetu organizacije i informatike (Jezgra za međunarodne projekte, FOI). Konzultiranjem eksperata, izvršene su određene promjene u interakciji klastera i čvorova u modelu te je dobiven ANP model prikazan na slici 6-13. Model je napravljen u alatu *SuperDecisions* koji zbog izbjegavanja vizualne konfuznosti, ne prikazuje sve poveznice između čvorova u modelu. Na slici 6-13. prikazane su veze između klastera u modelu, koje se mogu interpretirati na sljedeći način: a) strelica koja ide od jednog klastera prema drugom označava da je barem jedan čvor iz prvog klastera povezan s čvorom u drugom klasteru i b) ukoliko klaster sadrži petlju, ona se interpretira kao zavisnost barem jednog čvora u klasteru od drugog čvora u tom istom klasteru.



Slika 6-13. ANP model za donošenje odluke o uvođenju e-učenja u visoko školstvo

Kako bi se prikazale zavisnosti i interakcije između čvorova u modelu, njihove veze su prikazane u tablici 6-8. koja se naziva engl. *Reachability* matrica ili Matrica veza elemenata u ANP modelu (Salomon & Whitaker, 2007.). Za mrežu prikazanu na slici 6-13., matrica veza elemenata sastoji se od četiri bloka: (Alternative, Alternative), (Alternative, Kriteiji), (Kriteriji, Alternative) i (Kriteriji, Kriteriji). Broj 1 u ćeliji matrice veze elemenata označava da element retka utječe na element stupca u modelu to jest da element stupca zavisi od elementa retka. Ukoliko je samo jedna jedinica u stupcu bloka, to znači da je element stupca u potpunoj zavisnosti od elementa tog retka u kojem se nalazi 1. Ako se u stupcu bloka nalazi više od jedne jedinice, sljedeći korak je određivanje prioriteta utjecaja elemenata retka na elemente stupca. Elementi retka će u postupku ANP-a biti uspoređivani u parovima s ciljem utvrđivanja koji od njih utječe više na element stupca.

Tablica 6-8. Matrica veza elemenata u ANP modelu


		Alternative			Kriteriji																				
		Alt1	Alt2	Alt3	VN	VK	RSF	SR	FS	SC	POT	POM	POG	UNO	UPO	MI	RO	ISU	TO	RDM	SI	MVS	VAS	PVA	SS
Alt	Nastava uz pomoć ICT (Alt 1)	0	0	0	1	1	0	1	1	0	1	0	0	1	0	1	1	1	1	0	0	0	0	0	0
	Hibridna nastava (Alt 2)	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	Online obrazovanje (Alt 3)	0	0	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
Kriteriji	Vrednovanje/napredovanje sveuč. nastavnika (VN)	1	1	1	0	1	1	1	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0
	Vrednovanje i kontrola kvalitete na sveučilištu i fakultetu (VK)	1	1	1	1	0	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	Razvojna strategija fakulteta (RSF)	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	Sveučilišni razvojni okvir (SR)	1	1	1	1	1	1	0	1	1	0	0	0	1	1	0	1	0	0	1	0	0	0	0	0
	Financijska spremnost (FS)	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	Specijalizirani centri potpore e-učenju (SC)	0	1	1	1	0	0	0	0	0	1	1	1	1	1	0	0	1	0	1	1	1	1	1	1
	Pomoćno osoblje za tehničku potporu (POT)	1	1	1	0	1	0	0	0	1	0	0	0	1	0	0	0	1	0	0	1	0	0	0	0
	Pomoćno osoblje za metodičku potporu (POM)	1	1	1	0	1	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0
	Pomoćno osoblje za grafičko oblikovanje, animaciju i video (POG)	0	1	1	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	1
	Usavršavanje nastavnog osoblja (UNO)	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	1	0	0	0	1
	Usavršavanje pomoćnog osoblja (UPO)	1	1	1	0	0	0	0	0	0	1	0	0	0	0	1	0	1	0	0	1	1	1	1	1
	Mrežna infrastruktura (MI)	1	1	1	0	1	1	0	0	1	1	0	0	0	0	0	1	0	1	1	1	0	1	0	1
	Računalna opremljenost nastavnika i studenata (RO)	1	1	1	0	0	1	0	0	1	1	0	0	1	0	1	0	1	0	1	1	1	1	1	1
	Integralni sustav upravljanja procesom obrazovanja (ISU)	1	1	1	0	1	1	0	0	1	1	0	0	1	0	1	1	0	1	1	1	0	0	0	0
	Tehnička opremljenost na fakultetu (TO)	1	1	1	0	1	1	1	0	1	1	0	0	1	0	1	0	1	0	0	1	1	1	1	1
	Repozitorij digitalnog obrazovnog materijala (RDM)	0	1	1	1	1	0	0	0	1	0	0	0	1	0	0	1	0	1	0	1	0	0	0	1
	Sustav ispitivanja uz pomoć računala (SI)	0	1	1	0	1	0	0	0	0	0	0	0	1	1	0	1	0	1	0	0	0	0	0	1
	Mrežni videokonferencijski sustavi (MVS)	0	1	1	0	1	1	0	0	0	1	0	0	0	0	1	1	1	1	0	0	0	1	1	0
	Video i audio streaming (VAS)	0	1	1	0	0	0	0	0	0	1	0	1	0	0	0	1	0	1	0	0	0	0	1	0
	Proizvodnja audio i video materijala (PVA)	1	1	1	0	0	0	0	0	1	1	0	1	0	0	0	0	0	0	0	0	0	1	0	0
Sustavi za simulacije i virtualnu stvarnost (SS)	0	1	1	0	0	0	0	0	1	1	0	1	0	0	0	0	0	1	0	0	0	0	0	0	

6.2.2. Odlučivanje ANP metodom uz potporu alata Super Decisions

Softver *SuperDecisions* podržava primjenu AHP-a i ANP-a i koristi se pretežito u akademске svrhe. Razvili su ga Rozann Whitaker Saaty i William Adams (R. Saaty & Adams, 2005.) u kompaniji *Creative Decisions Foundation*. Softver je besplatan te se može skinuti na web stranici: <http://www.superdecisions.com>. Na navedenoj web stranici se nalazi i priručnik koji detaljno objašnjava sve mogućnosti korištenja *SuperDecisions* softvera u izgradnji složenih ANP modela (Tutorial on Complex Decision Models (ANP)). Opcije koje pruža alat *SuperDecisions* gotovo su identične opcijama alata *Expert Choice*, opisanim u poglavlju 5.2.2., pa se one ponovno neće opisivati. Ključna razlika je da *SuperDecisions* podržava i razvoj ANP modela te nudi tri predložka («čarobnjaka») za njihov što lakši razvoj: jednostavnu mrežu, mali predložak i potpuni predložak (Slika 6-14.). Alat *SuperDecisions* ne podržava grupno odlučivanje, ali se grupne odluke mogu donositi izračunavanjem geometrijske sredine procjena donositelja odluke.

Na web stranicama alata Super Decisions se za komercijalne svrhe preporuča korištenje alata *DecisionLens* (DecisionLens, 2007.). Softver *DecisionLens* podržava samo AHP metodu, ali trenutno je u tijeku razvoj nove verzije softvera koja će podržavati ANP metodu i koja će imati dodatnu funkciju strukturiranja problema odlučivanja na osnovu ponuđenih modula. Razvoj je poduprijet i financiran od strane Pentagona - sjedišta Ministarstva obrane SAD-a (Pentagon, U.S. Department of Defense).

ANP model o uvođenju e-učenja u visoko školstvo razvijen je i testiran u alatu *SuperDecisions* te su u interpretaciji rezultata korišteni izvještaji i screenshotovi navedenog alata.



Slika 6-14. Alat *SuperDecisions* – odabir predloška za kreiranje ANP modela

6.2.3. Odlučivanje o uvođenju e-učenja na visokoškolsku instituciju

U fazi razvijanja i izgradnje modela, razvijen je ANP model u kojeg su ugrađene složene interakcije između kriterija za odlučivanje. Testiranje ANP modela, točnije odlučivanje metodom analitičkog mrežnog procesa, izvršeno je od strane eksperta domene koji je član Povjerenstva za izradu strategije e-učenja Sveučilišta u Zagrebu i član Povjerenstva za izradu strategije e-učenja Fakulteta organizacije i informatike, te time kompetentan i sa odgovarajućim stupnjem odgovornosti za donošenje strateških odluka u domeni e-učenja. ANP model je testiran uz potporu alata *SuperDecisions*.

ANP metoda je primjenjena za donošenje strateških odluka na razini sveučilišta i fakulteta iz razloga što uzima u obzir međusobnu interakciju kriterija, te time znatno povećava stabilnost izabrane alternative pa je time logičniji izbor u donošenju odluka na višim strateškim razinama.

Ekspert domene je svojim procjenama postavio prioritete alternativa i težine kriterija te su dobiveni rezultati poslužili kao input u Strategiju e-učenja Sveučilišta u Zagrebu i Strategiju e-učenja Fakulteta organizacije i informatike (detaljnije u poglavlju 7.2.).

6.2.3.1. Izbor eksperta domene

Ekspert domene je odabran na način da svojim kompetencijama odgovara zadanom problemu, da može profitirati od rezultata dobivenih primjenom ANP metode u rješavanju problema, te da može utjecati na strateško planiranje uvođenja e-učenja u visoko školstvo u Hrvatskoj.

Ekspert domene je član projektnog tima projekta EQIBELT, član Povjerenstva za izradu strategije e-učenja Sveučilišta u Zagrebu (do 2007), član Povjerenstva za e-učenje (od 2008) i član Povjerenstva za izradu strategije e-učenja Fakulteta organizacije i informatike te mu je sudjelovanje u cjelokupnom istraživanju te primjena ANP metode u rješavanju problema uvođenja e-učenja u visoko školstvo, pomogla u strukturiranju strategije e-učenja Sveučilišta u Zagrebu i Fakulteta organizacije i informatike i u davanju preporuke o obliku e-učenja kojeg treba uvesti na određenu razinu u visokom školstvu u Hrvatskoj.

Kratka ekspertiza eksperta domene nalazi se u tablici 6-9.

Tablica 6-9. Ekspertiza eksperta domene

EKSPERTIZA EKSPERTA DOMENE	
-	članica Povjerenstva za izradu strategije e-učenja Sveučilišta u Zagrebu (do 2007) i Povjerenstva za e-učenje (od 2008)
-	članica Povjerenstva za izradu strategije e-učenja Fakulteta organizacije i informatike
-	članica projektnog tima projekta EQIBELT (Education Quality Improvement By E-learning Implementation)
-	doktorica znanosti
-	prodekanica za znanost na Fakultetu organizacije i informatike
-	znanstveno-nastavno zvanje izvanredni profesor
-	znanstveni radovi iz područja teorije odlučivanja vezano uz e-učenje
-	predavač na više stručnih i znanstvenih skupova s temama iz e-učenja
-	sudjelovala u više međunarodnih projekata vezanih uz e-učenje (Tempus, Eureka)
-	voditeljica Referalnog centra za prijavljivanje projekata e-obrazovanja te projektnog tima u CARN-etu koji je izradio preporuke za standardizaciju i valorizaciju e-learning materijala u Hrvatskoj.

6.2.3.2. Rezultati odlučivanja

ANP model je testiran za donošenje odluke o uvođenju e-učenja na razini visokoškolske institucije. Postupak testiranja modela proveo je ekspert domene u alatu *SuperDecisions* i postupak je trajao 2 sata i 30 minuta. Rezultati istraživanja doprinijeli su boljem razumijevanju problema od strane eksperta te pomogli u strukturiranju strategije e-učenja, definiranju plana aktivnosti i kvantitativnih pokazatelja koji služe za praćenje ostvarivanja strategija.

Ključno je naglasiti razliku u primjeni razvijenih AHP i ANP modela u odlučivanju. Ideja razvoja AHP modela je pomoć u odlučivanju o obliku uvođenja e-učenja na razini određenog kolegija ili katedre. Testiranje je provedeno za kolegij Matematika, kako bi se pokazala primjena razvijenog modela u rješavanju konkretnog problema. Ideja razvoja ANP modela i odlučivanje ANP metodom je pomoć u strukturiranju strategije e-učenja Sveučilišta u Zagrebu i strategije e-učenja Fakulteta organizacije i informatike. Prioriteti dobiveni u postupku ANP metode, služili su kao vodič u kreiranju i prihvaćanju strategije, a naročito u definiranju prioriteta te pokazatelja praćenja realizacije prioriternih aktivnosti (detaljnije u poglavlju 7.).

Na slici 6-15. *Rezultati odlučivanja eksperta domene ANP metodom – Težinski koeficijenti elemenata* prikazani su težinski koeficijenti elemenata kao granične vrijednosti i vrijednosti normalizirane po klasterima. Korišten je screenshot alata *SuperDecisions*.

Name	Normalized by Cluster	Limiting
1 Nastava uz pomoc ICT	0.25542	0.031396
2 Hibridna nastava	0.57453	0.070621
3 Online obrazovanje	0.17005	0.020903
1 Razvojna strategija fakulteta	0.39235	0.052760
2 Sveucilisni razvojni okvir	0.36118	0.048568
3 Financijska spremnost sveucilista i fakulteta	0.24648	0.033144
1 Vrednovanje i napredovanje sveucilisni~	0.26145	0.031282
2 Vrednovanje i kontrola kvalitete na sveucilistu~	0.73855	0.088364
1 Repozitorij digitalnog obrazovnog materijala	0.16556	0.032844
2 Sustav ispitivanja uz pomoc racunala	0.32648	0.064767
3 Mrezni videokonferencijski sust~	0.05877	0.011658
4 Video i audio streaming	0.09104	0.018060
5 Proizvodnja video i audio materijala	0.10616	0.021060
6 Sustavi za simulacije i virtualnu stvarnost	0.25199	0.049989
1 Mrezna infrastruktura	0.12184	0.011680
2 Racunalna opremljenost nastavnika i studenata	0.29610	0.028386
3 Integralni sustav upravljanja procesom obr~	0.30049	0.028807
4 Tehnicka opremljenost predavaonica i ucionica ~	0.28157	0.026993
1 Specijalizirani centri potpore e-ucenju	0.28073	0.092280
2 Pomocno osoblje za tehnicku potporu	0.22134	0.072758
3 Pomocno osoblje za metodicku potporu	0.04845	0.015925
4 Pomocno osoblje za graficko oblikovanje, an~	0.08015	0.026346
5 Usavršavanja nastavnog osoblja	0.28270	0.092930
6 Usavršavanje pomocnog osoblja	0.08664	0.028481

Slika 6-15. Rezultati odlučivanja eksperta domene ANP metodom – Težinski koeficijenti elemenata (screenshot alata *SuperDecisions*)

U tablici 6-10. nalazi se pregled dobivenih težinskih koeficijenata elemenata (čvorova) modela.

Tablica 6-10. Rezultati odlučivanja eksperta domene ANP metodom – Pregled težinskih koeficijenata elemenata

ELEMENTI ANP MODELA	Vrijednosti normalizirane po klasterina	Granične vrijednosti
FORMALNO – PRAVNA SPREMNOST OKRUŽENJA		
Vrednovanje i kontrola kvalitete na sveučilištu i fakultetu	0.73855	0.088364
Vrednovanje i napredovanje sveučilišnih nastavnika	0.26145	0.031282
ORGANIZACIJSKA I STRATEŠKA SPREMNOST OKRUŽENJA		
Razvojna strategija fakulteta	0.39235	0.052760
Sveučilišni razvojni okvir	0.36118	0.048568
Financijska spremnost sveučilišta i fakulteta	0.24648	0.033144
LJUDSKI RESURSI		
Usavršavanje nastavnog osoblja	0.28270	0.092930
Specijalizirani centri potpore e-učenju	0.28073	0.092280
Pomoćno osoblje za tehničku potporu	0.22134	0.072758
Usavršavanje pomoćnog osoblja	0.08664	0.028481
Pomoćno osoblje za grafičko oblikovanje, animaciju i video	0.08015	0.026346
Pomoćno osoblje za metodičku potporu	0.04845	0.015925
TEMELJNA ICT INFRASTRUKTURA		
Integralni sustav upravljanja procesom obrazovanja (MLEs)	0.30049	0.028807
Računalna opremljenost nastavnika i studenata	0.29610	0.028386
Tehnička opremljenost predavaonica i učionica na fakultetu	0.28157	0.026993
Mrežna infrastruktura	0.12184	0.011680
SPECIFIČNA ICT INFRASTRUKTURA		
Sustav ispitivanja uz pomoć računala	0.32648	0.064767
Sustavi za simulacije i virtualnu stvarnost	0.25199	0.049989
Repozitorij digitalnog obrazovnog materijala	0.16556	0.032844
Proizvodnja video i audio materijala	0.10616	0.021060
Video i audio streaming	0.09104	0.018060
Mrežni videokonferencijski sustavi	0.05877	0.011658

Na Slici 6-16. *Rezultati odlučivanja eksperta domene ANP metodom – Prioriteti alternativa* prikazani su prioriteti alternativa dobiveni procjenama eksperta domene. Rezultati su prikazani u tri moda: cjelokupan (engl. *total (raw)*), normalan (engl. *normal*) i idealan (engl. *ideal*). Normalan mod prikazuje normalizirane prioritete alternativa te njihova suma iznosi 1. Idealan mod prikazuje prioritete alternativa dobivene na način da je prioritet svake alternative podijeljen s prioritetom alternative koja ima najviši prioritet, u ovom slučaju to je alternativa «Hibridna nastava». Cjelokupan mod prikazuje vrijednosti uzete direktno iz granične supermatrice te mreže.

Alternatives	Total	Normal	Ideal	Ranking
Hibridna nastava	0.0706	0.5745	1.0000	1
Nastava uz pomoc ICT	0.0314	0.2554	0.4446	2
Online obrazovanje	0.0209	0.1701	0.2960	3

Slika 6-16. Rezultati odlučivanja eksperta domene ANP metodom – Prioriteti alternativa

Matrica klastera nastala uspoređivanjem važnosti klastera nalazi se na slici 6-17. Iz prvog stupca matrice možemo isčitati koji klasteri imaju najveći utjecaj na alternative.

Cluster Node Labels	1 Alternative	2 Organizacijska i strateska spremnost okruzenja	3 Formalno pravna spremnost okruzenja	4 Specificna ICT infrastruktura	5 Temeljna ICT infrastruktura	6 Ljudski resursi
1 Alternativ e	0.000000	0.061613	0.078089	0.200536	0.120939	0.087566
2 Organizacijska i strateska spremnost okruzenja	0.261774	0.285454	0.262278	0.166894	0.263349	0.000000
3 Formalno pravna spremnost okruzenja	0.109162	0.150720	0.112695	0.069606	0.081510	0.152891
4 Specificna ICT infrastruktura	0.208913	0.155195	0.171526	0.195405	0.209247	0.257291
5 Temeljna ICT infrastruktura	0.062476	0.069099	0.062215	0.098805	0.158696	0.087566
6 Ljudski resursi	0.357674	0.277919	0.313196	0.268753	0.166259	0.414687

Slika 6-17. Rezultati odlučivanja eksperta domene ANP metodom – Matrica klastera

Vrste supermatrica su opisane u točki 6.1.1. Neponderirane i ponderirane supermatrice dobivene testiranjem ANP modela nalaze se u prilogu 6. Slike 6-18.- 6-20. prikazuju graničnu supermatricu dobivenu testiranjem ANP modela od strane eksperta domene. Granična

supermatrica sadrži tzv. granične prioritete elemenata ANP modela koji su ujedno prikazani u tablici 6-10. (kolona *Granične vrijednosti*) i na slici 6-16. (kolona *Total*).

Cluster Node Labels		1 Alternative			2 Organizacijska i strateska spremnost okruzenja			3 Formalno pravna spremnost okruzenja	
		1 Nastava uz pomoc ICT	2 Hibrдна nastava	3 Online obrazovanje	1 Razvojna strategija fakulteta	2 Sveucilisni razvojni okvir	3 Financijska spremnost sveucilista i fakulteta	1 Vrednovanje i napredovanje sveucilisnih nastavnika	2 Vrednovanje i kontrola kvalitete na sveucilistu i fakultetu
1 Alternative	1 Nastava uz pomoc ICT	0.031396	0.031396	0.031396	0.031396	0.031396	0.031396	0.031396	0.031396
	2 Hibrдна nastava	0.070621	0.070621	0.070621	0.070621	0.070621	0.070621	0.070621	0.070621
	3 Online obrazovanje	0.020903	0.020903	0.020903	0.020903	0.020903	0.020903	0.020903	0.020903
2 Organizacijska i strateska spremnost okruzenja	1 Razvojna strategija fakulteta	0.052760	0.052760	0.052760	0.052760	0.052760	0.052760	0.052760	0.052760
	2 Sveucilisni razvojni okvir	0.048568	0.048568	0.048568	0.048568	0.048568	0.048568	0.048568	0.048568
	3 Financijska spremnost sveucilista i fakulteta	0.033144	0.033144	0.033144	0.033144	0.033144	0.033144	0.033144	0.033144
3 Formalno pravna spremnost okruzenja	1 Vrednovanje i napredovanje sveucilisnih nastavnika	0.031282	0.031282	0.031282	0.031282	0.031282	0.031282	0.031282	0.031282
	2 Vrednovanje i kontrola kvalitete na sveucilistu i fakultetu	0.088364	0.088364	0.088364	0.088364	0.088364	0.088364	0.088364	0.088364

Slika 6-18. Rezultati odlučivanja eksperta domene ANP metodom –Granična supermatrica 01

Cluster Node Labels		4 Specifična ICT infrastruktura						5 Temeljna ICT infrastruktura	
		1 Repozitorij digitalnog obrazovnog materijala	2 Sustav ispitivanja uz pomoc racunala	3 Mrežni videokonferencijski sustavi	4 Video i audio streaming	5 Proizvodnja video i audio materijala	6 Sustavi za simulacije i virtualnu stvarnost	1 Mrežna infrastruktura	2 Racunalna opremljenost nastavnika i studenata
4 Specifična ICT infrastruktura	1 Repozitorij digitalnog obrazovnog materijala	0.032844	0.032844	0.032844	0.032844	0.032844	0.032844	0.032844	0.032844
	2 Sustav ispitivanja uz pomoc racunala	0.064767	0.064767	0.064767	0.064767	0.064767	0.064767	0.064767	0.064767
	3 Mrežni videokonferencijski sustavi	0.011658	0.011658	0.011658	0.011658	0.011658	0.011658	0.011658	0.011658
	4 Video i audio streaming	0.018060	0.018060	0.018060	0.018060	0.018060	0.018060	0.018060	0.018060
	5 Proizvodnja video i audio materijala	0.021060	0.021060	0.021060	0.021060	0.021060	0.021060	0.021060	0.021060
	6 Sustavi za simulacije i virtualnu stvarnost	0.049989	0.049989	0.049989	0.049989	0.049989	0.049989	0.049989	0.049989
5 Temeljna ICT infrastruktura	1 Mrežna infrastruktura	0.011680	0.011680	0.011680	0.011680	0.011680	0.011680	0.011680	0.011680
	2 Racunalna opremljenost nastavnika i studenata	0.028386	0.028386	0.028386	0.028386	0.028386	0.028386	0.028386	0.028386

Slika 6-19. Rezultati odlučivanja eksperta domene ANP metodom –Granična supermatrica 02

Cluster Node Labels	5 Temeljna ICT infrastruktura		6 Ljudski resursi					
	3 Integralni sustav upravljanja procesom obrazovanja	4 Tehnicka opremljenost predavaonica i ucionica na fakultetu	1 Specijalizirani centri potpore e-ucenju	2 Pomocno osoblje za tehnicku potporu	3 Pomocno osoblje za metodicku potporu	4 Pomocno osoblje za graficko oblikovanje, animaciju i video	5 Usavršavanje nastavnog osoblja	6 Usavršavanje pomocnog osoblja
5 Temeljna ICT infrastruktura	3 Integralni sustav upravljanja procesom obrazovanja	0.028807	0.028807	0.028807	0.028807	0.028807	0.028807	0.028807
	4 Tehnicka opremljenost predavaonica i ucionica na fakultetu	0.026993	0.026993	0.026993	0.026993	0.026993	0.026993	0.026993
6 Ljudski resursi	1 Specijalizirani centri potpore e-ucenju	0.092280	0.092280	0.092280	0.092280	0.092280	0.092280	0.092280
	2 Pomocno osoblje za tehnicku potporu	0.072758	0.072758	0.072758	0.072758	0.072758	0.072758	0.072758
	3 Pomocno osoblje za metodicku potporu	0.015925	0.015925	0.015925	0.015925	0.015925	0.015925	0.015925
	4 Pomocno osoblje za graficko oblikovanje, animaciju i video	0.026346	0.026346	0.026346	0.026346	0.026346	0.026346	0.026346
	5 Usavršavanje nastavnog osoblja	0.092930	0.092930	0.092930	0.092930	0.092930	0.092930	0.092930
	6 Usavršavanje pomocnog osoblja	0.028481	0.028481	0.028481	0.028481	0.028481	0.028481	0.028481

Slika 6-20. Rezultati odlučivanja eksperta domene ANP metodom–Granična supermatrica 03

U interpretaciji rezultata, važno je naglasiti da je najveća važnost u strateškom planiranju uvođenja e-učenja na institucijsku razinu, stavljena na elemente «Usavršavanje nastavnog osoblja» i «Specijalizirani centri potpore e-učenju». Promatrajući granične prioritete, ta dva elementa imaju najviše vrijednosti: «Usavršavanje nastavnog osoblja» (0.0929) i «Specijalizirani centri potpore e-učenju» (0.0922) (Tablica 6-10.). Ujedno su ta dva elementa i elementi najveće važnosti u klasteru «Ljudski resursi», dok je klaster «Ljudski resursi» klaster najveće važnosti u ANP modelu s prioritetom od 0,35767 (vidi matricu klastera na slici 6-17.). Zanimljivo je da je u grupnom odlučivanju AHP metodom, podkriterij «Specijalizirani centri potpore e-učenju» dobio najmanji težinski koeficijent od 0,022 pod kriterijem «Ljudski resursi». Naime, specijalizirani centar potpore je vrlo važan kriterij u strateškom planiranju uvođenja e-učenja na sveučilišta i fakultete jer se centri potpore formiraju upravo na tim višim strateškim razinama, dok on ima manju važnost kada se odlučuje o obliku uvođenja e-učenja na nižu stratešku razinu, odnosno na određeni kolegij. U tom slučaju su puno važniji kriteriji usavršavanja nastavnog osoblja i usavršavanja pomoćnog osoblja.

Drugi klaster po važnosti u ANP modelu je klaster «Organizacijska i strateška spremnost okruženja» s prioritetom 0,26177 (slika 6-17.). Elementi s najvećim prioritetom u tom klasteru su «Razvojna strategija fakulteta» (0.3923) i «Sveučilišni razvojni okvir» (0.3611). S obzirom da je u testiranju ANP modela, okvir bio strategija Fakulteta organizacije i informatike, element «Razvojna strategija fakulteta» ima najveći prioritet, ali s vrlo malom

razlikom u odnosu na drugorangirani element «Sveučilišni razvojni okvir». Ukoliko vršimo usporedbu s AHP rezultatima na razini kolegija, drugorangirani kriterij po važnosti je kriterij «Financijska spremnost sveučilišta i fakulteta» što možemo interpretirati kao važnost financijskog motivatora za nastavnike i pomoćno osoblje pri uvođenju e-učenja na operativnoj razini kolegija (izrada i održavanje hibridnog ili online kolegija).

Klaster «Specifična ICT infrastruktura» (0,2089) treći je po redu rangirani klaster u ANP modelu. U ovom je klasteru stavljen naglasak na elemente čiji je razvoj prioritet u strateškom planiranju uvođenja e-učenja na institucijsku razinu s obzirom na trenutačno stanje i postojeću infrastrukturu u visokom školstvu. Najveći problem i nedostatak u izvođenju hibridne nastave i online nastave predstavlja «Sustav ispitivanja uz pomoć računala» (0.32648) i «Sustavi za simulacije i virtualnu stvarnost» (0.25199) koji nisu na odgovarajućoj razini razvoja i primjene. Gledajući rezultate dobivene AHP modelom, kriterij «Sustavi za simulacije i virtualnu stvarnost» nalazi se na zadnjem mjestu po važnosti u kriteriju «Raspoloživost specifične infrastrukture». Naime, ukoliko gledamo prijelaz određenog kolegija s klasične nastave na hibridnu nastavu ili nastavu online, kriteriji kao što su «Repozitorij digitalnog obrazovnog materijala», «Videokonferencijski sustavi» i «Audio i video materijal» su većeg prioriteta i lakše ih je realizirati kao preduvjete prijelaza određenog kolegija s klasične nastave na hibridnu ili online nastavu.

Klaster «Formalno-pravna spremnost okruženja» ima prioritet od 0.10916. S obzirom da smo ANP model primijenili za odlučivanje o strateškom planiranju uvođenja e-učenja na sveučilište i fakultete, element «Vrednovanje i kontrola kvalitete na sveučilištu i fakultetu» dobio je vrlo veliki prioritet od 0.088364 gledano u odnosu na ostale elemente modela i prioritet od 0.73855 unutar klastera «Formalno-pravna spremnost okruženja». Element «Vrednovanje i napredovanje sveučilišnih nastavnika» ima prioritet od 0.26145 unutar klastera, što ukazuje na manju važnost promocije nastavnika u okviru strateškog planiranja e-učenja na institucijskoj razini. Ukoliko izvršimo usporedbu s AHP rezultatima po istom klasteru/kriteriju, podkriterij «Sustav i kriteriji vrednovanja i promocije sveučilišnih nastavnika» i podkriterij «Sustav vrednovanja i kontrole kvalitete na sveučilištu i fakultetu» imaju jednaki težinski koeficijent od 0,175. Možemo zaključiti da je kod odlučivanja o obliku uvođenja e-učenja na razini kolegija, dodijeljena ista važnost i jednom i drugom kriteriju. Ukoliko usporedimo s ANP rezultatima, važnost podkriterija vrednovanja i promocije nastavnika veća je u AHP modelu. Priznavanje online materijala u sustavu vrednovanja i

promocije sveučilišnih nastavnika može se tumačiti kao jedan od faktora utjecaja na izradu online materijala za određeni kolegij od strane nastavnika.

Klaster «Temeljna ICT infrastruktura» s prioritetom od 0.062476 zadnje je rangirani klaster u ANP modelu. Slabi rang tog klastera može se protumačiti kroz zadovoljavajuću razinu temeljne ICT infrastrukture na gotovo svim institucijama visokog školstva u Hrvatskoj. Potreba za razvojem i unapređenjem je jedino vidljiva vezano uz integralni sustav upravljanja procesom obrazovanja, pa je taj element dobio i najveću važnost od 0.30049. Isti rezultat je dobiven kod AHP modela, s obzirom na ključnu ulogu integralnog sustava upravljanja procesom obrazovanja pri kreiranju hibridnog ili online kolegija.

Kod ANP modela nam dobiveni rang alternativa nije tako velike važnosti kao kod AHP modela, s obzirom da nam ANP model služi prvenstveno kao pomoć u izradi strategije institucije za uvođenje e-učenja, dok od AHP modela očekujemo preporuku za donošenje odluke o obliku uvođenja e-učenja na određeni kolegij. Međutim, možemo interpretirati rang alternativa dobiven evaluacijom ANP modela od strane eksperta domene: prvorangirana alternativa je «Hibridna nastava» (0.5745), zatim «Nastava uz pomoć ICT» (0.2554) i «Online obrazovanje» (0.1701). Velika nadmoć alternative «Hibridna nastava» nad ostalim alternativama, može se vrlo lako objasniti kao najbolji pokazatelj smjernica koje institucije visokog školstva trebaju slijediti. Naime, većina fakulteta u visokom školstvu u Hrvatskoj održava nastavu uz pomoć ICT-a. Fakulteti pioniri e-učenja u Hrvatskoj polako prijelaze s nastave uz pomoć ICT-a na hibridni oblik nastave na određenim programima ili kolegijima. Međutim, još je mnogo fakulteta u Hrvatskoj koje treba motivirati za uvođenje e-učenja (hibridnog oblika nastave) na određene kolegije ili programe. Naravno da su za uvođenje e-učenja bitni i određeni preduvjeti, koje je potrebno strateški isplanirati i osigurati kako bi se implementacija e-učenja uspješno provela u zadanim okvirima. Prvi korak je izrada strategije za e-učenje na sveučilišnoj i fakultetskoj razini.

7. UTJECAJ REZULTATA DOBIVENIH ODLUČIVANJEM AHP I ANP METODOM

U sedmom poglavlju prikazan je utjecaj rezultata dobivenih odlučivanjem AHP i ANP metodom na uvođenje e-učenja na kolegij Matematika i izradu Strategije e-učenja Sveučilišta u Zagrebu i Fakulteta organizacije i informatike.

Uz pomoć razvijenog AHP modela, odlučivalo se o obliku uvođenja e-učenja na kolegij Matematika na Katedri za kvantitativne metode na Fakultetu organizacije i informatike. Rezultati odlučivanja su detaljnije interpretirani i prikazani u poglavlju 5.2.3. Preporuka za uvođenje e-učenja na kolegij Matematika bila je uvođenje hibridnog oblika nastave, čije uvođenje je uspješno završeno, a detalji su opisani u poglavlju 7.1.

Odlučivanje ANP modelom služilo je kao okvir za strukturiranje Strategije e-učenja Sveučilišta u Zagrebu te kao potpora u kreiranju Strategije e-učenja Fakulteta organizacije i informatike. Kvalitativna analiza Strategije e-učenja Sveučilišta u Zagrebu i Strategije e-učenja Fakulteta organizacije i informatike, nalazi se u poglavlju 7.2.

7.1. Hibridni model nastave na kolegiju Matematika

Cilj grupnog odlučivanja provedenog AHP metodom bio je donijeti odluku o obliku uvođenja e-učenja na kolegij Matematika na Katedri za kvantitativne metode na Fakultetu organizacije i informatike.

Rezultati odlučivanja pokazali su da alternativa „Hibridna ili mješovita nastava“ ima najveći prioritet te da se uvođenje hibridnog modela nastave preporučuje za kolegij Matematika 1. Uvođenje hibridnog oblika nastave na kolegij Matematika 1 uspješno je završeno, te je kolegij Matematika 1 služio kao pilot kolegij pri uvođenju e-učenja na ostale kolegije na FOI-u.

Sudionici procesa grupnog odlučivanja AHP metodom: nositeljica kolegija, asistenti na kolegiju te web master i održavatelj LMS sustava na FOI (poglavlje 5.2.3.1.), kreirali su kolegij Matematika 1 u hibridnom obliku. Prema strategiji e-učenja Fakulteta organizacije i informatike te objašnjenju razina «hibridne nastave» na FOI (Prilog 8, Tablica 2), kolegij Matematika 1 nalazi se na prijelazu s razine 2 na razinu 3. Na kolegiju su ispunjeni gotovo svi

uvjeti razine 2, osim foruma vezano uz svaku nastavnu cjelinu, a ispunjeni su i neki od uvjeta razine 3. U tablici 7-1. nalazi se popis svih uvjeta hibridne nastave koji su zadovoljeni na kolegiju Matematika 1 na sveučilišnom preddiplomskom studiju.

Tablica 7-1. Objašnjenje razine «hibridne nastave» za kolegij Matematika 1

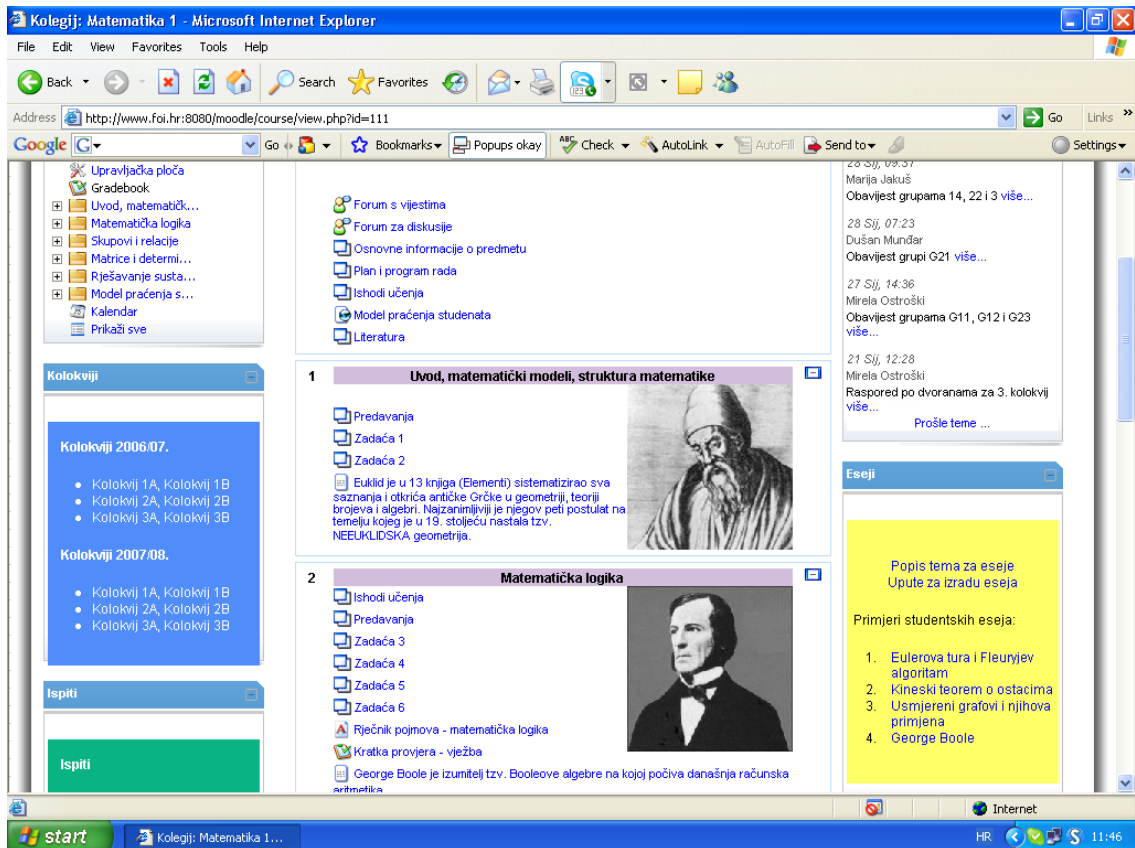
Razina FOI	Cilj	Uvjeti
Razina 2 - 3	<ul style="list-style-type: none"> ▪ Olakšati usvajanje znanja kroz bolju integraciju LMS sustava s klasičnom nastavom ▪ Unaprijediti nastavne metode i tehnike podučavanja putem hibridne organizacije kolegija 	<ul style="list-style-type: none"> ▪ Većina nastavnih materijala organizirana prema nastavnim cjelinama (predavanja, seminari, vježbe) i dostupna preko LMS sustava ▪ Razrađen forum: generalni forum s vijestima, forum za diskusije ▪ Kalendar važnijih događanja za kolegij (rokovi za kolokvije, zadaće...) ▪ Obavijesti vezane uz kolegij (generalne obavijesti, rezultati kolokvija, zadaća....) ▪ Samoprovjere/provjere znanja po pojedinim nastavnim cjelinama ▪ Bodovanje svih relevantnih studentskih on-line aktivnosti (diskusije, pristup materijalima, provjere znanja...) ▪ Predavanje i ocjenjivanje zadaća, seminara, testova putem LMS-a ▪ Pojmovnik

Struktura kolegija Matematika 1 u LMS sustavu sastoji se od 7 modula: uvodni modul, 5 osnovnih sadržajnih cjelina i modul praćenja studenata. U uvodnom modulu nalazi se forum s vijestima i forum za diskusije, osnovne informacije o predmetu, plan i program rada na predmetu, ishodi učenja za cijeli predmet te popis literature.


Svaka od 5 sadržajnih cjelina sadrži jednaku strukturu: popis ishoda učenja za tu cjelinu, nastavne materijale za tu cjelinu u *.pdf* i *.pds* formatu, rječnik pojmova, zadaće i kratke provjere. Nastavni materijali se za svaku cjelinu tjedno dograđuju sa *SMART Board* bilješkama s predavanja. Nastavnici na kolegiju redovito dograđuju i ažuriraju nastavne materijale. Demonstrator na kolegiju također dograđuje nastavni materijal s prezentacijama koje priprema za demonstrature. Bodovanje svih relevantnih studentskih on-line aktivnosti vrši se redovito preko modula model praćenja studenata. Postoje dvije vrste zadaća: klasične i individualne zadaće. Kod klasičnih zadaća, zadaće se zadaju preko LMS-a, a studenti ih predaju na nastavi ili preko LMS-a, a također se ocjenjuju preko LMS sustava. Individualne

zadace odnosno samoprovjere su složene po taksonomiji MATH-KIT (Cox, 2003.) koja obuhvaća tri kategorije: K- engl. *Knowledge* (osnovno znanje - definiranje i razumijevanje pojmova, poznavanje primjera, upotreba pojmova i činjenica, praktično korištenje tehnika računanja), I – engl. *Interpretation* (interpretacija - shvaćanje, razumijevanje, analiza i sinteza) i T – engl. *Transfer* (transfer - prevođenje znanja u novi kontekst). Pitanja se kombiniraju nasumično iz te tri kategorije te time svaki student dobiva na rješavanje drugačiji test, ali test približno iste težine.

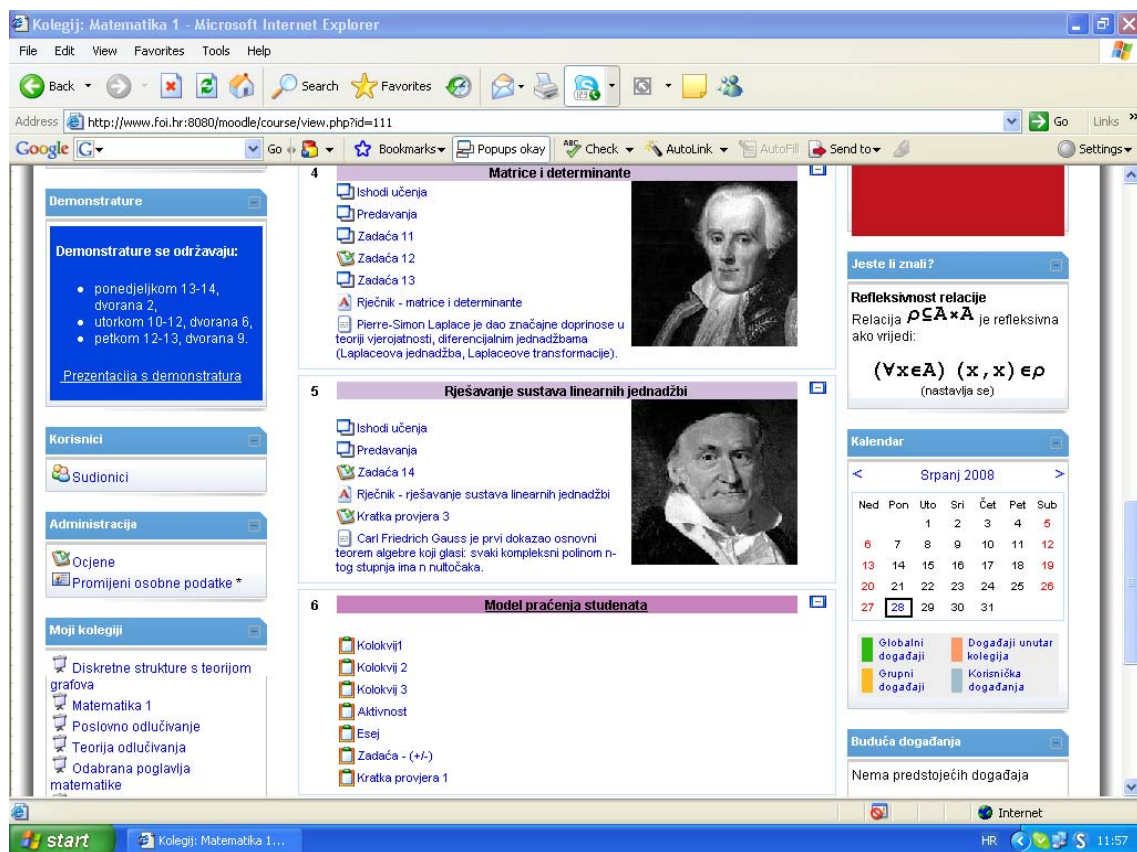
U modulu modela praćenja studenata nalazi se objašnjenje svih zadataka (aktivnosti, kolokvija, zadaća, kratkih provjera) koje studenti izvršavaju kako bi skupili bodove za završnu ocjenu. U bloku Administracija vodi se evidencija bodova studenata za svaku od aktivnosti. Od ostalih opcija, potrebno je naglasiti da postoji kalendar važnijih događanja za kolegij, preko kojeg student može pratiti rokove za kolokvije, zadace, provjere, te mu služi kao vremenski podsjetnik njegovih obveza. Vrlo je korisna i kategorija «Jeste li znali?» koja studentima daje uvid u zanimljivosti iz područja Matematike te im omogućava proširenje osnovnog znanja dodatnim informacijama. Ujedno je napravljena i poveznica ove kategorije prema Pojmovniku. Kategorija koja studentima pruža mogućnost da prošire svoje znanje je i kategorija Linkovi koja daje pregled korisnih linkova koji studentima mogu poslužiti kao dodatna literatura. Sučelje kolegija Matematika 1 u LMS sustavu *Moodle* prikazan je preko screenshotova na slikama 7-1.-7-3.



Slika 7-1. Hibridni oblik učenja na kolegiju Matematika 1 u sustavu Moodle (Screenshot 01)



Slika 7-2. Hibridni oblik učenja na kolegiju Matematika 1 u sustavu Moodle (Screenshot 02)



Slika 7-3. Hibridni oblik učenja na kolegiju Matematika 1 u sustavu Moodle (Screenshot 03)

7.2. Strategija e-učenja Sveučilišta u Zagrebu i Fakulteta organizacije i informatike

Istraživanje provedeno u okviru ove doktorske disertacije (poglavlje 4) i ANP model razvijen na temelju tog istraživanja (poglavlje 6) služili su kao okvir za strukturiranje Strategije e-učenja Sveučilišta u Zagrebu (prilog 7) te kao potpora u kreiranju Strategije e-učenja Fakulteta organizacije i informatike (prilog 8).

Strategija e-učenja Sveučilišta u Zagrebu izrađena je u okviru TEMPUS projekta EQIBELT (detaljnije u poglavlju 3.1.2.). Na radionici projekta EQIBELT pod nazivom «Vizija i strategija e-učenja u visokom obrazovanju u Hrvatskoj» provedena je anketa čiji rezultati su poslužili za definiranje okvira Strategije uvođenja e-učenja Sveučilišta u Zagrebu i kreiranje Strategije e-učenja Fakulteta organizacije i informatike. Anketa je provedena s ciljem prikupljanja stavova sudionika radionice o ulozi i ciljevima e-učenja i o kriterijima za odluku o implementaciji e-učenja. Anketu su provele prof.dr.sc. Blaženka Divjak i Nina Begičević uz

podršku i pomoć mr.sc. Zorana Bekića, voditelja projekta EQIBELT (Bilten EQIBELT, 2006.).

Strategiju e-učenja Sveučilišta u Zagrebu je izradilo i predložilo Povjerenstvo za izradu strategije e-učenja Sveučilišta u Zagrebu, imenovano na 8. sjednici Senata u 338. akademskoj godini, održanoj 13. veljače 2007 godine. Strategija je raspravljena i prihvaćena na 14. sjednici Senata Sveučilišta u Zagrebu u 338. akademskoj godini, održanoj 12. lipnja 2007. godine.

U Strategiji su naglasci stavljeni na strateške ciljeve koji se nastoje ostvariti uvođenjem e-učenja, na prednosti uvođenja e-učenja te na područja strateškog djelovanja i planirane aktivnosti u procesu uvođenja e-učenja. Rezultati ankete provedene na prvoj radionici EQIBELT projekta poslužili su kao pomoć u definiranju ciljeva, prednosti i planiranih aktivnosti u Strategiji. Anketom su se prikupljale ocjene o važnosti ciljeva i prednosti uvođenja e-učenja te kriterija i podkriterija odlučivanja tijekom strateškog planiranja uvođenja e-učenja na hrvatska sveučilišta i fakultete. Detaljnije o strukturi ankete te rezultatima anketiranja u poglavljima 4.3. i 4.4. Dokument «Strategija e-učenja 2007. – 2010. Sveučilišta u Zagrebu» nalazi se u prilogu 7.

U Strategiji e-učenja Sveučilišta u Zagrebu navode se četiri strateška cilja koja Sveučilište u Zagrebu namjerava ostvariti uvođenjem i aktivnom primjenom e-učenja:

- unaprijediti kvalitetu sveučilišnog obrazovanja,
- omogućiti nastavnicima i studentima ostvarivanje novih uloga u obrazovnom procesu,
- povećati konkurentnost Sveučilišta i sveučilišnih studijskih programa i
- osposobiti studente za uporabu tehnologija cjeloživotnog učenja.

U poglavlju «E-učenje» Strategije e-učenja Sveučilišta u Zagrebu, navedene su i objašnjene prednosti uvođenja e-učenja:

- vremenska i prostorna fleksibilnost u podučavanju i učenju,
- fleksibilan (vremenski i prostorno) pristup ažurnim i aktualnim multimedijalnim i interaktivnim nastavnim materijalima, integrirani u nastavu pristup hrvatskim i svjetskim repozitorijima obrazovnih sadržaja, digitalnim knjižnicama, arhivima i muzejima,
- mogućnost prilagođavanja osobnom stilu učenja,
- omogućavanje kolaborativnog učenja i stjecanje vještina projektnog i timskog rada,

- dostupnost širem krugu studenata (studenti s posebnim potrebama, studenti na udaljenim lokacijama, strani studenti i slično).

U poglavlju «Područja strateškog djelovanja i planirane aktivnosti» Strategije e-učenja Sveučilišta u Zagrebu, navode se područja strateškog djelovanja koja su preuzeta iz rezultata anketiranja (kriteriji odlučivanja tijekom strateškog planiranja uvođenja e-učenja na hrvatska sveučilišta i fakultete), dok su u osmišljavanju planiranih aktivnosti poslužili podkriteriji odlučivanja koji su također sastavni dio ankete. Aktivnosti u strategiji su planirane unutar sljedećih područja strateškog djelovanja:

A Unapređenje formalno-pravnog i organizacijskog okruženja, osiguravanje održivosti

B Razvoj ljudskih potencijala

C Podrška nastavnicima

D Podrška studentima

E Razvoj obrazovnih sadržaja

F Razvoj temeljne i specifične infrastrukture.

Strategija sadrži i kvantitativne pokazatelje koji služe praćenju ostvarivanja strategije odnosno uvjeta za primjenu i razine primjene e-učenja na Sveučilištu u Zagrebu tijekom razdoblja od 2007. do 2010. godine (Prilog 7).

Iz navednih primjera, vidljivo je da su rezultati ankete provedene na prvoj radionici projekta EQIBELT, bili polazište za definiranje «Strategije e-učenja na Sveučilištu u Zagrebu».

Strategija e-učenja Fakulteta organizacije i informatike izrađena je od strane Povjerenstva za izradu strategije e-učenja Fakulteta organizacije i informatike. Pripremile su je prof.dr.sc. Blaženka Divjak i Nina Begičević, dok su analizu stanja na FOI-u izradili Darko Grabar i Mate Boban. Nakon rasprava i potrebnih izmjena, Strategija je u prosincu 2007. godine prihvaćena od strane Fakultetskog vijeća.

Strategija e-učenja Fakulteta organizacije i informatike (prilog 8) usklađena je sa Strategijom e-učenja na Sveučilištu u Zagrebu, što je razumljivo s obzirom da je Fakultet organizacije i informatike jedna od sastavnica Sveučilišta u Zagrebu. Izrada strategije temeljena je na rezultatima istraživanja provedenog u okviru ove doktorske disertacije. Strateški ciljevi uvođenja e-učenja na FOI, definirani su u skladu s anketom. Navedeni su sljedeći strateški ciljevi:

1. Unaprijediti kvalitetu obrazovnog procesa i ishoda učenja
2. Osposobiti studente - buduće građane društva znanja za cjeloživotno učenje
3. Omogućiti bolji i širi pristup obrazovanju potencijalnim studentima
4. Osigurati izlazak na međunarodno tržište – internacionalizacija obrazovanja i istraživanja e-učenja.

Lista prednosti uvođenja e-učenja je u Strategiji e-učenja FOI-a prikazana u obliku tablice i proširena u odnosu na listu u Strategiji e-učenja Sveučilišta u Zagrebu. Lista prednosti u potpunosti je preuzeta iz ankete (poglavlje 4.3.1.). Kao prednosti uvođenja e-učenja navode se:

1. Mogućnost kolaborativnog učenja (dinamička interakcija s profesorima i studentima)
2. On-line pristup nastavnim materijalima (informacije su lakše dostupne)
3. Mogućnost cjeloživotnog učenja
4. Neovisnost o vremenu i prostoru – fleksibilnost učenja
5. Objedinjavanje različitih medija za prijenos i prikaz informacija (interaktivni sadržaji za učenje i različiti mediji za prezentiranje sadržaja)
6. Mogućnost prilagođavanja osobnom stilu učenja studenta (student uči samostalno organizirajući vrijeme, personalizirani pristup)
7. Omogućava da se vrijeme koje profesor i student imaju na raspolaganju iskoristi za najkvalitetnije obrazovne sadržaje, raspravu i prijenos znanja
8. Omogućava širi pristup obrazovanju (grupama studenata s posebnim potrebama)
9. Nastavnik lakše i kvalitetnije ažurira sadržaje novim spoznajama.

U strategiji e-učenja FOI-a, napravljen je i opis stanja e-učenja i utjecaja okruženja (prilog 8, poglavlje 2), a sastavni dio strategije je i opis oblika učenja s obzirom na razinu primjene ICT-a u nastavi (Prilog 8, Tablica 1) te objašnjenje tri razine hibridne nastave koja se primjenjuje ili će se primjenjivati na Fakultetu organizacije i informatike (Prilog 8, Tablica 2).

U planiranim aktivnostima i područjima strateškog djelovanja FOI-a, strategija je rukovođena Strategijom e-učenja Sveučilišta u Zagrebu i nastavlja se na planirane rezultate. Aktivnosti su rapoređene unutar istih područja strateškog djelovanja kao i u Strategiji Sveučilišta u Zagrebu, a po uzoru na rezultate ankete.

Strategija sadrži i kvantitativne pokazatelje koji služe za praćenje ostvarivanja strategije odnosno uvjeta za primjenu i razine primjene e-učenja na Fakultetu organizacije i informatike tijekom razdoblja od 2008. do 2010. godine (Prilog 8).

U Prilogu strategije, tzv. Objašnjenju pojmova, nalazi se objašnjenje svih pojmova koji bi mogli biti nejasni u okviru izrađene strategije e-učenja FOI-a. Cjelokupan pojmovnik, koji je sastavni dio strategije, preuzet je iz ankete – objašnjenje kriterija i podkriterija (poglavlje 5.2.1. i prilog 8).

Iz provedene analize Strategije e-učenja FOI je vidljivo da su rezultati istraživanja dobiveni u okviru ove doktorske disertacije uvelike pomogli u kreiranju «Strategije e-učenja Fakulteta organizacije i informatike».

8. ZAKLJUČAK

Kako bi se pravilno interpretirao zaključak rada, potrebno je potvrditi realizaciju ciljeva i ispitati točnost provjere postavljenih hipoteza istraživanja. Rezultati su sljedeći:

a) Realizacija ciljeva istraživanja

Realizacija cilja vezanog uz sistematizaciju strategija e-učenja vodećih europskih sveučilišta i fakulteta

U sklopu provedenog istraživanja izvršena je sistematizacija strategija e-učenja vodećih europskih sveučilišta i fakulteta. Svrha sistematizacije strategija e-učenja i znanstvenih i stručnih izvora o e-učenju bila je analiza postojećeg stanja u strateškom planiranju uvođenja e-učenja u visokoškolske institucije te *benchmarking* analiziranih strategija. Sistematizacija strategija e-učenja vodećih europskih sveučilišta i fakulteta nalazi se u poglavlju 4.3.1.

Realizacija cilja vezanog uz identifikaciju prednosti i ciljeva e-učenja te kriterija za odlučivanje kod uvođenja e-učenja u visoko školstvo u Hrvatskoj na temelju primjera strategija e-učenja vodećih europskih sveučilišta i fakulteta

Na temelju rezultata kvalitativne analize primjera strategija e-učenja vodećih europskih sveučilišta i fakulteta te znanstvenih i stručnih izvora o e-učenju, definirani su ciljevi i prednosti e-učenja te je razvijen teoretski model (kriteriji i podkriteriji) za strateško planiranje i donošenje odluke o uvođenju e-učenja. Time je realiziran drugi cilj ovog rada (opisano u poglavlju 4.3.1.).

Realizacija cilja vezanog uz ocjenu važnosti prednosti i ciljeva e-učenja te važnosti kriterija odlučivanja kod uvođenja e-učenja

U sklopu provedenog istraživanja je realiziran i treći cilj rada. Teoretski model razvijen na temelju rezultata kvalitativne analize, koristio je kao podloga za kreiranje ankete koja je provedena s ciljem prikupljanja i prioritizacije podataka potrebnih za izradu strateških

dokumenata: ciljeva uvođenja e-učenja, prednosti uvođenja e-učenja i kriterija važnih za strateško planiranje i odlučivanje o uvođenju e-učenja.

Anketa je provedena među stručnjacima koji poznaju visoko školstvo i posjeduju teoretska ili praktična znanja iz e-učenja (opisano u poglavlju 4.3.2.). Od ispitanika je traženo da ocjenama od 1-5 vrednuju prednosti i ciljeve uvođenja e-učenja, te da odrede važnost kriterija za odlučivanje o uvođenju e-učenja na sveučilišta i fakultete u Hrvatskoj (opisano u poglavlju 4.3.1.).

U obradi prikupljenih podataka je primijenjena metoda deskriptivne statistike kako bi se provela statistička analiza rezultata anketiranja i kako bi se grafički prikazale prosječne ocjene važnosti ciljeva i prednosti uvođenja e-učenja te prosječne ocjene važnosti kriterija odlučivanja za uvođenje e-učenja na sveučilišta i fakultete. Rezultati statističke obrade opisani su u poglavlju 4.4.1.

Realizacija cilja vezanog uz odlučivanje o uvođenju e-učenja na razini katedre i/ili kolegija pomoću AHP modela

U drugom djelu petog poglavlja (5.2.) prikazan je proces razvoja AHP modela za donošenje odluke o uvođenju e-učenja na razini katedre, za pojedinačni kolegij, koji je razvijen na temelju rezultata faktorske analize provedene na podacima prikupljenim anketom.

Model ima svoju primjenu u strukturiranju problema i procesu odlučivanja, služi za odlučivanje o obliku uvođenja e-učenja na razini određene katedre i/ili kolegija, a uz pomoć takvog modela donositelji odluke se mogu lakše fokusirati na strateške vrijednosti dobivenih rješenja i koristiti ih za povećanje učinkovitosti i razvoj sustava u planiranom smjeru.

Testiranje AHP modela izvršeno je grupnim odlučivanjem o obliku uvođenja e-učenja na kolegij Matematika 1, na Katedri za kvantitativne metode, na Fakultetu organizacije i informatike. Rezultati testiranja su opisani u poglavlju 5.2.3.

Realizacija ciljeva vezanih uz odlučivanje o uvođenju e-učenja na razini sveučilišta i/ili fakulteta pomoću ANP modela i potpore strateškom planiranju i izradi strateških dokumenata uvođenja e-učenja u okviru Tempus projekta EQIBELT (za Sveučilište u Zagrebu) i Fakulteta organizacije i informatike

U sklopu provedenog istraživanja je realiziran i jedan od osnovnih ciljeva ovog rada koji se odnosio na razvoj ANP modela i odlučivanje o uvođenju e-učenja na razini sveučilišta i fakulteta (opisano u poglavlju 6.2.).

Cilj razvoja ANP modela za donošenje odluke o uvođenju e-učenja u visokoškolsku instituciju, bio je pomoć u izradi strategije e-učenja Sveučilišta u Zagrebu i Fakulteta organizacije i informatike te potpora odlučivanju o obliku uvođenju e-učenja na razini sveučilišta i fakulteta pomoću ANP modela (opisano u poglavljima 6.2.3.2. i 7.2.).

ANP metoda je primijenjena za donošenje strateških odluka na razini sveučilišta i fakulteta jer uzima u obzir međusobnu interakciju kriterija, te time znatno povećava stabilnost izabrane alternative i predstavlja bolji izbor u potpori odlučivanju na višim strateškim razinama.

Testiranje modela je proveo ekspert domene koji je svojim procjenama postavio prioritete alternativa i težine kriterija te su dobiveni rezultati poslužili kao input u Strategiju za e-učenje Sveučilišta u Zagrebu i Fakulteta organizacije i informatike. Rang alternativa dobiven evaluacijom ANP modela od strane eksperta domene, pokazao je veliku nadmoć alternative «Hibridna nastava» nad ostalim alternativama, te su time definirane smjernice daljnjeg razvoja i unapređenja učenja i podučavanja na institucijama visokog školstva (opisano u poglavlju 6.2.3.2.). Fakulteti pioniri e-učenja u Hrvatskoj polako prijelaze s nastave uz pomoć ICT-a na hibridni oblik nastave na određenim programima ili kolegijima. Međutim, još je mnogo fakulteta u Hrvatskoj koje treba motivirati za uvođenje e-učenja (hibridnog oblika nastave) na određene kolegije ili programe.

b) Odgovor na hipoteze istraživanja

1. Potvrđuje se 1. hipoteza: U procesu strateškog planiranja uvođenja e-učenja na visokoškolske institucije, identificirani su ciljevi, prednosti i kriteriji uvođenja e-učenja te je ocjenjena važnost ciljeva i prednosti e-učenja te važnost kriterija za odlučivanje kod uvođenja e-učenja.

U poglavlju 4. interpretirani su rezultati kvantitativnih metoda istraživanja: ankete, deskriptivne statistike, faktorske analize i klasteriranja metodom k srednjih vrijednosti te rezultati kvalitativne analize primjera strategija e-učenja vodećih europskih sveučilišta i fakulteta. Navedene kvantitativne i kvalitativne metode primijenjene su u postupku potvrđivanja prve hipoteze. Rezultati istraživanja: identificirani ciljevi i prednosti uvođenja e-učenja te kriteriji za odlučivanje kod uvođenja e-učenja i ocjene njihove važnosti, opisani su u poglavljima 4.3. i 4.4.

2. Potvrđuje se 2. hipoteza: Na temelju definiranih kriterija je razvijen AHP model te je testiranjem modela potvrđeno da se grupnim odlučivanjem metodom analitičkog hijerarhijskog procesa može donijeti odluka o obliku uvođenja e-učenja na razini određene katedre, a za pojedini kolegij.

AHP model za višekriterijsko odlučivanje o obliku uvođenja e-učenja na razini određene katedre i kolegija, razvijen je na temelju kriterija i podkriterija reduciranih u postupku faktorske analize. Detaljno objašnjenje kriterija i podkriterija te alternativa, nalazi se u poglavlju 5.2.1.

Testiranje modela je provedeno grupnim odlučivanjem o obliku uvođenja e-učenja na kolegij Matematika, na Katedri za kvantitativne metode, na Fakultetu organizacije i informatike. Postupak grupnog odlučivanja i rezultati odlučivanja prikazani su u poglavlju 5.2.3. Razvojem i testiranjem AHP modela potvrđena je druga hipoteza.

3. Potvrđuje se 3. hipoteza: Razvojem ANP modela modelirane su interakcije između kriterija za odlučivanje u procesu strateškog planiranja uvođenja e-učenja na razini sveučilišta i fakulteta.

ANP model za višekriterijsko odlučivanje o obliku uvođenja e-učenja u visokoškolsku instituciju, razvijen je na temelju reduciranog skupa kriterija i složenih interakcija modeliranih između kriterija i alternativa odlučivanja (opisano u poglavlju 6.2.). Zavisnosti i povratne veze između

čvorova i klastera (kriterija, podkriterija i alternativa) u ANP modelu, postavljene su na temelju znanja prikupljenog pregledom literature, a evaluirane su od strane eksperata domene (opisano u poglavlju 6.2.1.).

Testiranje modela je provedeno od strane eksperta domene odlučivanjem o problemu uvođenja e-učenja na razini institucije uz potporu ANP modela. Postupak odlučivanja ANP metodom i rezultati odlučivanja prikazani su u poglavlju 6.2.3. Razvojem i testiranjem ANP modela potvrđena je treća hipoteza.

c) Zaključak

Istraživanje provedeno u okviru ove doktorske disertacije, svojim je rezultatima dalo doprinos strateškom planiranju i donošenju odluka u procesu uvođenja e-učenja u visoko školstvo u Hrvatskoj. Primjenom kvalitativnih i kvantitativnih metoda istraživanja, izvršeno je prikupljanje i analiza podataka potrebnih u izradi strateških dokumenata za uvođenje e-učenja (strategija e-učenja visokoškolskih institucija): ciljeva i prednosti e-učenja te kriterija odlučivanja važnih za strateško planiranje i donošenje odluka o uvođenju e-učenja.

Na temelju prikupljenih podataka, razvijeni su modeli za višekriterijsko odlučivanje: AHP i ANP modeli, koji imaju svoju primjenu u donošenju odluka (na razini sveučilišta, fakulteta, katedre i kolegija) u procesu strateškog planiranja uvođenja e-učenja na visokoškolske institucije u Hrvatskoj. Razvijeni AHP i ANP modeli omogućuju sistematizaciju znanja, pripremu scenarija odlučivanja o uvođenju e-učenja na visokoškolske institucije, konkretno donošenje odluke o određenom problemu odlučivanja (uzevši u obzir kvalitativne i kvantitativne aspekte odluke i konzistentnost donositelja odluke), fokusiranje na strateške vrijednosti dobivenih rješenja, povećanje učinkovitosti implementacije novih oblika učenja i podučavanja i razvoj sustava u planiranom smjeru. Društvena opravdanost istraživanja vidi se u doprinosu koje je istraživanje dalo u postupku kreiranja strategije e-učenja Sveučilišta u Zagrebu i strategije e-učenja Fakulteta organizacije i informatike te u razvoju AHP i ANP modela koji mogu služiti kao modeli za odlučivanje o obliku uvođenja e-učenja na različite razine (sveučilišta, fakulteta, katedre, kolegija) u visokom školstvu.

Znanstveni doprinos istraživanja vidi se u primjeni AHP i ANP metoda koje su po prvi puta primijenjene kao potpora u rješavanju problema strateškog planiranja uvođenja e-učenja te u njihovoj integraciji s drugim metodama (anketa, deskriptivna statistika, faktorska analiza). AHP metoda je jedna od najpoznatijih metoda za višekriterijsko odlučivanje s velikim spektrom primjena, međutim AHP model koji rješava probleme u domeni strateškog planiranja e-učenja, nije do sada razvijen niti primijenjen u rješavanju te vrste problema. ANP metoda nikada prije nije primjenjivana za rješavanje problema u domeni visokog školstva, a njenih primjena općenito ima malo i gotovo sve su iz 2005. i 2006. godine.

U postupku razvoja AHP i ANP modela primijenjena je i po prvi puta kombinirana (mješovita) metoda istraživanja koja je obuhvatila sljedeće metode: anketu kojom su prikupljeni podaci od eksperata, deskriptivnu statistiku za obradu prikupljenih podataka, klasteriranje (grupiranje) za analizu podataka te faktorsku analizu za reduciranje podataka prikupljenih anketom i definiranje kriterija potrebnih za razvoj AHP i ANP modela. Važno je naglasiti i kombinaciju ekspertiza ispitanika u istraživanju, odnosno da su u istraživanju sudjelovali isključivo ispitanici koji su eksperti i u području e-učenja i visokog školstva.

DD (FOI Sveučilište Zagreb)

Tekući broj:
(Sveučilište-Zagreb)

Doktorska disertacija

UDK: 005.642:37.018.43(043.3)

VIŠEKRITERIJSKI MODELI ODLUČIVANJA U STRATEŠKOM PLANIRANJU UVOĐENJA E-UČENJA

N.Begičević

Fakultet organizacije i informatike, Varaždin, Hrvatska

Istraživanje koje je provedeno u ovoj doktorskoj disertaciji daje svoj doprinos u procesu strateškog planiranja uvođenja e-učenja na visokoškolske institucije u Hrvatskoj. U procesu strateškog planiranja i donošenja odluke o uvođenju e-učenja izdvojene su četiri osnovne faze: (1) faza istraživanja problema, (2) faza razvijanja i izgradnje modela, (3) faza donošenja odluka i (4) faza provođenja odluke. U fazi istraživanja problema precizno je definiran centralni problem te je provedena situacijska analiza koja uključuje pregled i prezentaciju ključnih faktora i trendova vezanih uz definirani problem. U fazi razvijanja i izgradnje modela, na temelju mnogih znanstvenih i stručnih izvora, te primjera strategija e-učenja vodećih europskih fakulteta, identificirani su ciljevi i prednosti e-učenja te kriteriji za odlučivanje na temelju kojih je kreirana anketa čiji cilj je bio prikupljanje podataka od ispitanika stručnjaka za e-učenje u visokom školstvu. Rezultati anketiranja obrađeni su faktorskom analizom koja je reducirala definirane kriterije odnosno reducirala veći broj varijabli na manji broj faktora. U fazi donošenja odluke, na temelju rezultata faktorske analize, razvijeni su modeli za višekriterijsko odlučivanje: Analitički hijerarhijski proces (AHP) i Analitički mrežni proces (ANP) koji služe kao potpora u donošenju odluke o uvođenju e-učenja u visoko školstvo na višim razinama (sveučilišta i fakulteta) te nižim razinama (katedre i kolegija). U disertaciji su opisani metodološki i matematički temelji AHP i ANP metode. Navedene su prednosti i nedostaci AHP i ANP metode te je dan uvid u najpoznatiju računalnu podršku AHP metodi – programski alat *Expert Choice* i računalnu podršku ANP metodi – programski alat *SuperDecisions*. Prikazan je proces razvoja AHP modela za donošenje odluke o uvođenju e-učenja na razini određene katedre ili kolegija. Testiranje modela izvršeno je grupnim odlučivanjem o obliku uvođenja e-učenja na kolegij Matematika, na Katedri za kvantitativne metode, na Fakultetu organizacije i informatike. Razvijen je i ANP model za donošenje odluke o uvođenju e-učenja u visoko školstvo. ANP model je razvijen uz potporu alata *Super Decisions*, a testiranje modela je proveo ekspert domene na strateškom problemu odlučivanja o uvođenju e-učenja na visokoškolsku instituciju. U okviru disertacije su prikazani i rezultati kvalitativne analize Strategije e-učenja na Sveučilištu u Zagrebu i Strategije za e-učenje Fakulteta organizacije i informatike. Provedenom analizom utvrđen je doprinos rezultata istraživanja kreiranju Strategije e-učenja Sveučilišta u Zagrebu i Strategije za e-učenje Fakulteta organizacije i informatike.

Rad nije objavljen.

Voditelji:

prof. dr. sc. Tihomir Hunjak
prof. dr. sc. Blaženka Divjak

Povjerenstvo za ocjenu:

Prof.dr.sc. Tihomir Hunjak
Prof.dr.sc. Blaženka Divjak
Prof.dr.sc. Neven Vrčec
Prof.dr.sc. Zoran Babić

Povjerenstvo za obranu:

Prof.dr.sc. Tihomir Hunjak
Prof.dr.sc. Blaženka Divjak
Prof.dr.sc. Neven Vrčec
Prof.dr.sc. Zoran Babić
Prof.dr.sc. Neven Brumec

Datum obrane: 17. prosinac 2008.

Datum promocije: 13. rujan 2009.

Rad je pohranjen na Fakultetu organizacije i informatike, Varaždin

(stranica 228, slika 77, tablica 47, priloga 8, bibliografskih podataka 175, original na hrvatskom jeziku)

N. Begičević

DD (FOI)

UDK: 005.642:37.018.43(043.3)

Tekući broj _____

1. Višekriterijski modeli odlučivanja u
strateškom planiranju uvođenja e-učenja

E-učenje
Strategija
Višekriterijsko odlučivanje
AHP
ANP

I. Begičević N.

II. Fakultet organizacije i informatike, Varaždin,
Republika Hrvatska

DD (FOI Univers, Zagreb)

Current file number:
(University of Zagreb)

Doctoral Dissertation

UDC: 005.642:37.018.43(043.3)

Multicriteria decision making models for strategic planning of e-learning implementation

N. Begicevic

Faculty of Organization and Informatics, Varazdin, Republic of Croatia

This doctoral dissertation investigates strategic planning of e-learning implementation at universities/faculties in Croatia. Strategic planning of e-learning implementation includes decision making about the most suitable form of implementing e-learning on different levels in HE (high education) institutions. Decision making about e-learning implementation has been covered as consisting of four phases: (1) intelligence, (2) design, (3) choice and (4) implementation. During the Intelligence phase we have precisely identified our central decision problem and have conducted situation analysis. In the Design phase we have developed alternatives and established criteria and subcriteria. The questionnaire about the importance of the advantages and goals of e-learning implementation and about criteria and subcriteria significant for decision making was created. Essential for the survey was use of Croatian e-learning experts that are familiar with higher education (HE) environment. Further, we connected these findings with the results of the factor analysis which was performed on the survey. The results of the factor analysis have served as input in the multicriteria decision models AHP and ANP that we have developed in the Choice phase. In the implementation phase we have solved the problem of prioritisation of e-learning options with the help of multi-criteria modelling in the process of group decision making based on the AHP model and individual (expert) decision making based on the ANP model.

The specific objectives of this doctoral dissertation are: development of the theoretical model for strategic planning of e-learning implementation based on the results of the conducted survey, validation of the theoretical model for strategic planning of e-learning implementation by means of factor analysis, presentation of the structure of the AHP and ANP models for decision making about e-learning implementation, comparison between developed AHP and ANP models, analysis of the results of group decision making supported by sw TeamEC2000 based on the AHP model and the results of decision making supported by sw Super Decisions 1.6.0. based on the ANP model. The models can be applied at the course level, for the group of courses (department level) or at the study program (faculty level). At the same time the proposed models are useful for structuring discussion on strategic decisions on e-learning implementation and for creating strategies for e-learning implementation at the university and faculty level.

The thesis has not been published.

Supervisors:

Prof.dr.sc. Tihomir Hunjak

Prof.dr.sc. Blaženka Divjak

Appointed members for evaluation of dissertation:

Prof.dr.sc. Tihomir Hunjak

Prof.dr.sc. Blaženka Divjak

Prof.dr.sc. Neven Vrček

Prof.dr.sc. Zoran Babić

Appointed members for oral examination:

Prof.dr.sc. Tihomir Hunjak

Prof.dr.sc. Blaženka Divjak

Prof.dr.sc. Neven Vrček

Prof.dr.sc. Zoran Babić

Prof.dr.sc. Neven Brumec

Oral examination: 17 December 2008

Degree conferred: 13 September 2009

The dissertation is deposited at the Faculty of Organization and Informatics,
Varazdin.

(pages 228, figures 77, tables 47, references 175, appendices 8, original in Croatian)

N.Begicevic

DD (FOI)

UDK: 005.642:37.018.43(043.3)

Current number _____

1. Multicriteria decision making models for
strategic planning of e-learning
implementation

E-learning
Strategy
Multicriterial decision making
AHP
ANP

I. Begičević N.

II. Faculty of Organization and Informatics,
Varazdin, Republic of Croatia

Bibliografija radova:

Znanstveni radovi:

1. Begičević, N., Divjak, B., Hunjak, T.: Development of AHP based model for decision making on e-learning implementation, *Journal of Information and Organizational Sciences*, VOL 31, NO.1 (2007), Faculty of Organization and Informatics, Varaždin, 2007., p. 13-25
2. Begičević, N., Divjak, B., Hunjak, T.: Prioritization of e-learning forms: a multicriteria methodology, *Central European Journal of Operations Research CEJOR 2007*, Physica-Verlag, A Springer Company, Vol. 15, Issue 4, December 2007, ISSN 1435-246X
3. Fabac, R., Begičević, N., Vukadinović, D.: Knowledge society and decision making in organizations - A formal approach framework, *CNSI - 2007, International Conference on Advances and Systems Research*, October 25th - 27th 2007, Zadar, Croatia
4. Rupčić N., Begičević N.: E-learning potentials in building academic institutions as learning organizations, *6th International Symposium "Economy & Business 2007"*, International scientific publications, Sunny Beach, Bulgaria, 2007.
5. Bubaš G., Balaban I., Begičević N.: Course Evaluation in e-Learning by Comparative Analysis of Two or More e-Learning Courses, *18th International Conference on Information and Intelligent Systems IIS 2007*, Varaždin, 2007., p. 65-72.
6. Begičević N., Divjak B., Hunjak T.: Comparison between AHP and ANP: Case study of strategic planning of e-learning implementation, *ISAHP 2007*, Viña Del Mar, Chile, August- 3-8, 2007.
7. Bubaš G., Balaban I., Begičević N.: Evaluation of Online Courses as an Element of Instructional Design: The Case of Two Hybrid University Courses, *Proceedings of the 30th MIPRO 2007 International Convention in Opatija*, Vol. IV., MIPRO, 2007., p. 216-222.
8. Kliček B., Gerić S., Begičević N.: Data Collection in the Green Patrol project, *Our Economy - Review of Current Issues in Economics*, Vol. 53, No. 1-2, Maribor (FEB), Slovenia, 2007., p. 108. - 116.
9. Begičević N., Divjak B.: Validation of theoretical model for decision making about e-learning implementation, *Journal of Information and Organizational Sciences*, VOL 30, NO.2 (2006), Faculty of Organization and Informatics, Varaždin, 2006., p. 171-185
10. Begičević N., Divjak B., Hunjak T.: Development of AHP based model for decision making on e-learning implementaton, *17th International Conference on Information and Intelligent Systems IIS 2006*, Varaždin, 2006., p. 375-383.
11. Hunjak T., Begičević N.: Prioritisation of e-learning forms based on pair-wise comparisons, *Journal of Information and Organizational Sciences*, 30 (2006), Faculty of Organization and Informatics, Varaždin, 2006., p. 47-63
12. Begičević N., Klačmer M., Gerić S.: Innovative approach in management decision making, *8th International conference on linking Systems Thinking, Innovation, Quality, Entrepreneurship and Environment, STIQE 2006*, Maribor, Slovenia, 2006., p. 17-23
13. Divjak B., Begičević, N.: Imaginative Acquisition of Knowledge - Strategic Planning of E-Learning, *ITI 2006 Proceedings of the 28th International*

- Conference on Information Technology Interfaces, University Computing Centre SRCE, University of Zagreb, 2006., p. 47-53
14. Kliček B., Gerić S., Begičević N.: Innovative approach in environmental satisfaction survey - The green patrol case, 8th International conference on linking Systems Thinking, Innovation, Quality, Entrepreneurship and Environment, STIQE 2006, Maribor, Slovenia, 2006., p.87-93
 15. Hunjak T., Begičević N.: How to choose the most suitable form of implementing e learning?, 16th International Conference on Information and Intelligent Systems IIS 2005, Varaždin, 2005., p. 169-179.
 16. Baracska Z., Begičević N., Hruška D.: Modeling e-learning system in high education by DoctUS knowledge-based system: the case of Croatia, Beijing International Conference On Applied Business Research BICABR 2005, Beijing, China, 2005.
 17. Kliček B., Gerić S., Begičević N.: Models of intelligent organizations functioning, Proceedings of the 28th MIPRO 2005 International Convention in Opatija, 2005., p. 40-46.
 18. Zver B., Begičević N., Gerić S.: Od informacija do informacijskih sustava, Zbornik radova XIII., Sveučilište u Mostaru, Ekonomski fakultet Mostar, Mostar, 2004., p. 100-115.

Znanstveni istraživački workshop:

1. Begičević N., Divjak B., Hunjak T.: Decision making model for strategic planning of e-learning implementation, Fourth EDEN (European Distance and E-learning Network) Research Workshop, Research into Online Distance Education and E-learning: Making the difference, October 2006, Barcelona-Castelldefels, Spain

Pozvano predavanje:

1. Begičević N., Hunjak T., Fučić L.: AHP based model for comparison of Public Administration Bodies, 22nd European Conference on Operational Research, EURO XXII, July 2007, Prague, Czech Republic

Stručni radovi:

1. Bubaš G., Balaban I., Begičević N.: Evaluacija on-line tečaja kao obrazovne komponente u hibridnom sveučilišnom kolegiju, CUC 2006, CARNet, studeni 2006., Dubrovnik, Hrvatska
2. Begičević N., Vidović S.: Grupno odlučivanje AHP metodom podržano sw TeamEC 2000, Business Process Conference 2006, listopad 2006., Zagreb, Hrvatska
3. Begičević N., Divjak B.: Strateško planiranje uvođenja e-učenja na sveučilištima i fakultetima, Edupoint časopis, CARNet, godište VI, rujan 2006.
4. Begičević N., Vidović S.: Grupno odlučivanje AHP metodom - odlučivanje o razini uvođenja obrazovanja na daljinu u visoko školstvo, lipanj 13-15, 2005., Opatija, Croatia, CASE 17, Zbornik radova savjetovanja CASE 17

ŽIVOTOPIS

Nina Begičević		Datum i mjesto rođenja
Fakultet organizacije i informatike Varaždin		12. ožujak 1980., Varaždin
Pavlinska 2, 42 000 Varaždin		Kućna adresa:
Tel. 042/390-857		Stjepana Vukovića 8a, 42 000 Varaždin
Fax. 042/213-413		
e-mail: nina.begicevic@foi.hr		
OBRAZOVANJE		
2003.-2006.	poslijediplomski znanstveni studij „Menadžment poslovnih sustava“, Fakultet organizacije i informatike Sveučilišta u Zagrebu	
1998.-2003.	diplomski studij „Informacijski sustavi“, Fakultet organizacije i informatike Sveučilišta u Zagrebu	
1994.-1998.	srednjoškolsko obrazovanje – Gimnazija Varaždin	
ZAPOSLENJA		
2005. -	znanstveni novak na Katedri za kvantitativne metode i na Katedri za organizaciju, kolegiji: Teorija odlučivanja, Poslovno odlučivanje, Metode za višekriterijsko odlučivanje - Fakultet organizacije i informatike	
2003. – 2005.	stručni suradnik na projektu E!2584 Eurotourism Ulixes – Intelligent Tourist Organization, stručni suradnik u nastavi na kolegiju Teorija odlučivanja - Fakultet organizacije i informatike	
AKADEMSKI NASLOVI		
2003.	diplomirani informatičar (diplomski rad: „Marketing virtualnih organizacija“ - mentor prof.dr.sc. Božidar Kliček).	

Nina Begičević

LITERATURA

1. Aczel, J., Saaty, T., L.: Procedures for synthesizing ratio judgment, *Journal of Mathematical Psychology*, 27:93-102, 1983.
2. Aczel, J., Alsina, C.: On synthesis of judgments, *Social-Economic Planning Sciences*, 20:333-339, 1986.
3. Aczel, J., Hardy P., Cotinat, O., Igglden, H. (Eds.): Identifying innovation in higher education elearning strategies, Fourth EDEN (European Distance and E-learning Network) Research Workshop, Research into Online Distance Education and E-learning: Making the difference, Barcelona-Castelldefels, Spain, 2006.
4. Agarwal, A., R. Shankar: On-line trust building in e-enabled supply chain, *Supply Chain Management: An International Journal* 8 (4), pp. 324-334, 2003.
5. Alphonse C., B.: Application of the Analytic Hierarchy Process in agriculture in developing countries, *Agricultural Systems*, 53, 97-112, 1997.
6. Aras, H., Erdoğmuş and E. Koç: Multi-criteria selection for a wind observation station location using analytic hierarchy process, *Renewable Energy* 29 (2004) (8), pp. 1383–1392., 2004.
7. Babic, Z., Plazibat, N.: Ranking of enterprises based on multicriterial analysis, *International Journal of Production Economics*, Volume: 56-7, pp. 29-35, September 20, 1998.
8. Bates, T.: *Managing technological change. Strategies for college and university leaders.* San Francisco, CA, 2000.
9. Bates, T.: *National strategies for e-learning in post-secondary education and training*, Paris: UNESCO, 2001., <<http://unesdoc.unesco.org/images/0012/001262/126230e.pdf>>, (pristupano: 05.05.2006.)
10. Bates, A., Tony, W.: *Upravljanje tehnološkim promjenama, Strategije za voditelje visokih učilišta*, Zagreb/Lokve, CARNet, Zagreb, 2004.
11. Bates, A.: *Strategy and Visions of e-learning in Higher Education*, Zagreb, Croatia, 2005., <<http://eqibelt.srce.hr/lectures/bates.html>>, (pristupano: 10.03.2006.)
12. Bayazit, O.: Use of AHP in decision-making for flexible manufacturing systems, *Journal of Manufacturing Technology Management*, Vol. 16, No. 7, 2005.
13. Bayazit, O.: Use of Analytic Network Process in Vendor Selection Decisions, *Benchmarking: An International Journal* 3 (5), pp. 566-579, 2006.
14. Begičević, N., Divjak, B.: „Utjecaj e-učenja na kvalitetu visokog obrazovanja“, publikacija Rezultati projekta Referalnog centra za upravljanje kvalitetom u organizacijama visokog školstva, financiran od Nacionalne zaklade za znanost, visoko školstvo i tehnologijski razvoj Republike Hrvatske, FOI Varaždin, listopad 2006.
15. Begičević, N., Divjak, B., Hunjak, T.: Prioritization of e-learning forms: a multicriteria methodology, *Central European Journal of Operations Research CEJOR* 2007, Physica-Verlag, A Springer Company, Vol. 15, Issue 4, December 2007, ISSN 1435-246X

16. Belton, V.: A comparison of the Analytic Hierarchy Process and a simple multiattribute value function, *European Journal of Operational Research* 26, pp. 7-21, 1986.
17. Bilten Tempus projekta EQIBELT (Education Quality Improvement by E-Learning Technology), broj 1 / studeni 2005., ISSN 1845-7991
18. Bilten Tempus projekta EQIBELT (Education Quality Improvement by E-Learning Technology), broj 3 / studeni 2006., ISSN 1845-7991
19. Bilten Tempus projekta EQIBELT (Education Quality Improvement by E-Learning Technology), broj 4, rujan/listopad 2007., ISSN 1845-7991
20. Blair, A., R., Nachtmann, R., Saaty, T.L., Whitaker, R.: Forecasting the resurgence of the US economy in 2001: An expert judgement approach, *Socio-Economic Planning Sciences* 36 (2002), pp. 77–91., 2002.
21. Boezerooij, P.: E-learning strategies of higher education institutions, UNITISK, CHEPS/UT, 2006, An exploratory study into the influence of environmental contingencies on strategic choices of higher education institutions, 2006.,
<<http://www.utwente.nl/cheps/documenten/thesisboezerooij.pdf>>, (pristupano:10.05.2006)
22. Boucher, T., O., Luxhoj, J., T., Descovich T., Litman, N.: Multicriteria evaluation of automated filling systems: A case study, *Journal of Manufacturing Systems* 12 (1993) (5), pp. 357–378., 1993.
23. Brace N., Kemp R., Snelgar R.: *SPSS for Psychologists: A guide to data analysis using SPSS for windows*, New York, N.Y: Palgrave, 2000.
24. Chedid, R., B. : Policy development for solar water heaters: The case of Lebanon, *Energy Conversion and Management* 43 (2002), pp. 77–86., 2002.
25. Chen, S., H., H. T. Lin, H. T. Lee: Enterprise Partner Selection for Vocational Education: Analytic Network Process Approach." *International Journal of Manpower* 25 (7), pp. 643-655, 2004.
26. Chen, Z., H. Li, S. C. W. Kong, Q. Xu: An Analytic Knowledge Network Process for Construction Entrepreneurship Education, *Journal of Management Development* 25 (1), pp. 11-27, 2006.
27. Cheng, E., W., H. Li: Analytic Network Process Applied to Project Selection, *Journal of Construction Engineering and Management* 131(4), pp. 459-466, 2005a.
28. Cheng, E., W., H. Li, L. Yu: The Analytic Network Process (ANP) Approach to Location Selection: A Shopping Mall Illustration." *Construction Innovation* 5 (2), pp. 83-98, 2005b.
29. Collis, B., A., Wende, M.C. van der (Eds.): *Models of Technology and Change in Higher Education, An international comparative survey on the current and future use of ICT in Higher Education*. Enschede; University of Twente, 2002.
30. Collis, B., A., Moonen, J.: *Flexible learning in a digital world: experiences and expectations*. London UK:Kogan Page, 2001.
31. Cox, W.: A Math-KIT for engineers, *Teaching Mathematics and its Applications*, 22 (4), pp. 193 – 198, 2003.

32. Creswell, J., W. : Research Design - Qualitative, Quantitative and Mixed Methods Approaches, Second Edition, University of Nebraska, Lincoln, SAGE Publications, 2003.
33. Curran, C.: Strategies for e-learning in universities, Research & Occasional Paper Series: CSHE.7.04, Center for Studies in Higher Education, September 2004.,
<<http://cshe.berkeley.edu/publications/docs/ROP.Curran.7.04.pdf>>, (pristupano: 20.05.2006.)
34. Divjak, B., Begičević, N.: Imaginative Acquisition of Knowledge - Strategic Planning of E-Learning, Proceedings of the 28th International Conference on Information Technology Interfaces, ITI 2006, University Computing Centre SRCE, 2006., str. 47-53.
35. Divjak, B., Prišćan, S., Hoić-Božić, N., Hudec, G., Kukolja, Teradi S., Pervan, P., Špiranec, S., Taradi, M.: Standardization and valorisation of digital educational materials, 16th IIS International Conference Proceedings, Varaždin, 2005.
36. Dyer, F., R., Forman, E., H.: An Analytic Approach to Marketing Decisions, Prentice-Hall International, Inc; 1991.
37. Dyer, F., R.: Remarks on the Analytic Hierarchy Process, Management Science 36 (3), pp. 249-258, 1990.
38. Expert Choice, Inc. (2000), Expert Choice Decision Support Software, RWS publications, Pittsburg, USA, 2000., <<http://www.expertchoice.com/>>, (pristupano: 20.03.2005.)
39. Ergdogmus, S., Aras, H., Kos, E.: Evaluation of Alternative Fuels for Residential Heating in Turkey Using Analytic Network Process with Group Decision Making." Renewable and Sustainable Energy Reviews 10 (3), pp. 269-279., 2006.
40. Fiala, P.: An ANP/DNP Analysis of Economic Elements in Today's World Economy." Journal of Systems Science and Systems Engineering 15 (2), pp. 131-140, 2005.
41. Forman, E., Selly, M., A.: Decision By Objectives (How to convince others that you are right), Expert Choice Inc., 2007. <<http://www.expertchoice.com/assets/dbo/chapter4.pdf>>
42. Frei, Harker: Measuring aggregate process performance using AHP, European Journal of Operational Research 16 (1999) (2), pp. 436-442., 1999.
43. Frishammar, J.: Information use in strategic decision making, Management Decision, Volume 41, Number 4, 2003 , pp. 318-326(9)
44. Fulgosi, A.: Faktorska analiza, Školska knjiga, Zagreb, 1988.
45. Garuti, C., Spencer, I.: Parallels between the analytic hierarchy and network processes (AHP/ANP) and fractal geometry, Mathematical and Computer Modelling, Volume 46, Issues 7-8, October 2007, pp. 926-934
46. Hamalainen, R., P.: Reversing the Perspective on the Applications of Decision Analysis, Decision Analysis, Vol. 1, No.1, March 2004.
47. Harker, P., T., Vargas, L., G.: The theory of ratio scale estimation: Saaty's analytic hierarchy process, Management Science, 1987.; 33(1):1383-403.
48. Hirschheim, R.: The Internet-Based Education Bandwagon: look before you leap, Communications of the ACM, Volume 48, Issue 7

- <<http://portal.acm.org/citation.cfm?id=1070844&coll=Portal&dl=ACM&CFID=50988184&CFTOKEN=11242346>>, (pristupano: 20.07.2005.)
49. Horton, W.: *Designing Web – Based Training*, Wiley, USA, 2000.
 50. Hough, J., R., Wite, A., M.: Scanning actions and environmental dynamism: Gathering information for strategic decision making, *Management Decision*, Vol. 42 No. 6, 2004, pp. 781-793
 51. Howell, S., L., Williams, P., B., Lindsay, N., K.: Thirty-two trends affecting distance education: An informed foundation for strategic planning, *Online Journal of Distance Learning Administration*, 6(3), 2003., <<http://www.westga.edu/~distance/ojdla/fall63/howell63.html>>, (pristupano: 25.03.2005.)
 52. Hui, Y., V., Leung, L., C., Fu, G., Cheung, W.: Designing a Fourth-Party E-Commerce Logistic Centre: A Benefit, Cost, and Risk Analysis Using AHP and ANP Models, *International Journal of Internet and Enterprise Management* 1 (1), pp. 53-74, 2003.
 53. Hunjak, T., Begičević, N.: Prioritisation of e-learning forms based on pair-wise comparisons, *Journal of Information and Organizational Sciences - JIOS*, Vol. 30, No. 1, Varaždin, 2006., str. 47-63.
 54. Hunjak, T., Jakovčević, D.: AHP based model for bank performance evaluation and rating, *ISAHP 2001*, Berne, Switzerland, 2001.
 55. Hunjak, T.: Višekriterijsko odlučivanje, poglavlje u knjizi: Čerić, V., Varga, M., (eds)(2004): *Informacijska tehnologija u poslovanju*, Element, Zagreb, 2004.
 56. Huzak: Vjerojatnost i matematička statistika, predavanja s Poslijediplomskog stručnog studija aktuarske matematike, siječanj 2003., <<http://degiorgi.math.hr/aktuari/doc/vms.pdf>>, (pristupano: 01.12.2006.)
 57. Ho, W.: Integrated analytic hierarchy process and its applications – A literature review, *European Journal of Operational Research* 186 (2008), pp. 211-228., 2008.
 58. Karlsson, J., Wohlin, C., Regnell, B.: An evaluation of methods for prioritizing software requirements, *Information and Software Technology*, 39 (14-15), 939-947, 1998.
 59. Karsak, E., E., Sozer, S., Alptekin, S., E.: Product Planning in Quality Function Deployment Using the Analytic Network Process, *Computers and Industrial Engineering* 44, pp. 171-190, 2002.
 60. Kim, P., O., Lee, K., J., Lee, B., W.: Selection of an optimal nuclear fuel cycle scenario by goal programming and the analytic hierarchy process, *Annals of Nuclear Energy* 26 (1999), pp. 449–460., 1999.
 61. Ko, S., Fontane, D., G., Margeta, J.: Multiple reservoir system operational planning using multi-criterion decision analysis, *European Journal of Operational Research*, Volume: 76, Issue: 3, pp. 428-439, August 11, 1994.
 62. Kyong-Jee Kim, Curtis J. Bonk, TingTing Zeng: Surveying the future of workplace e-learning: The rise of blending, interactivity, and authentic learning, *eLearn*, Volume 2005,

Issue 6, <<http://elearnmag.org/subpage.cfm?section=research&article=5-1>>, (pristupano: 20.07.2005.)

63. Kwak, N., K., Lee, C.: A multicriteria decision-making approach to university resource allocations and information infrastructure planning, *European Journal of Operational Research* 110, 1998.
64. Lai, V., S., Wong B., K., Cheung, W.: Group decision making in a multiple criteria environment: A case using the AHP in software selection, *European Journal of Operational Research* 137 (2002), pp. 134–144., 2002.
65. Lee, C., W., Kwak, N., K.: Information resource planning for a health-care system using an AHP based goal programming method, *Journal of the Operational Research Society* 50 (1999), pp. 1191–1198., 1999.
66. Leung, L., C., Lam, K., C., Cao, D.: Implementing the Balanced Scorecard Using the Analytic Hierarchy Process & the Analytic Network Process, *Journal of the Operational Research Society* 57 (6), pp. 682-691, 2006.
67. Lootsma, F., A.: Scale sensitivity and rank preservation in a multiplicative variant of the AHP and Smart, Report 91-67, Faculty of Technical Mathematics and Informatics, Delft University of Technology, Delft, Netherlands, 1991.
68. Markkula, M.: Improving Learning through Technology: Opportunities for All, The PROMETEUS Conference, CNIT – Paris La Défense, France, 2002.
69. Maurer, H.: Necessary Aspects of Quality in eLearning Systems (in: *Quality Education @ a Distance* (Eds: G. Davies, E. Stacey), Kluwer Academic Publishers, 29-37), 2003., <http://www.iicm.edu/iicm_papers/>, (pristupano: 15.05.2005.)
70. Meade, L., M.: R&D Project Selection Using the Analytic Network Process, *IEEE Transactions on Engineering Management* 49 (1), 2002.
71. Meade, L., M., J. Sarkis: Strategic Analysis of Logistics and Supply Chain Management Systems Using the Analytical Network Process, *Transportation Research* 34 (3), pp. 201-215, 1998.
72. Mintzberg, H.: *Structure in Fives, Designing Effective Organizations*, McGill University, 1993.
73. Mohanty, R., P., Agarwal, R., Choudhury, A., K., Tiwari, M., K.: A Fuzzy ANP-Based Approach to R&D Project Selection: A Case Study, *International Journal of Production Research* 43 (24), pp. 5199-5216, 2005.
74. Mohanty, R., P., Deshmukh, S., G.: Use of analytic hierarchic process for evaluating sources of supply, *International Journal of Physical Distribution and Logistics Management* 23 (1993) (3), pp. 22–28., 1993.
75. Morrison, D.: *E-learning Strategies, How to get implementation and delivery right first time*, Wiley, 2003.

76. Mu, E.: The First Ten Years of Using The Analytic Network Process (ANP): A Literature Review, Invited Paper, The Institute for Operations Research and Management Science, INFORMS (Institute for Operations Research and the Management Sciences), Annual Meeting, Pittsburgh, November 2006.
77. Narasimhan, R.: An Analytical Approach to Supplier Selection, *Purchasing and Materials Management*, 19(1), 27-32, 1983.
78. Oblinger, D., G., Hawkins, B., L.: The myth about E-learning, *Educause review*, 2005.
79. Panian, Ž., Klepac, G.: *Poslovna inteligencija*, Masmedia, 2003.
80. Parker, M.: Technology-enhanced e-Learning: perceptions of first year information systems students at the Cape Technikon, *Proceedings of SAICSIT 2003*, 2003., pp. 316-319
<<http://portal.acm.org/results.cfm?coll=Portal&dl=ACM&CFID=50988184&CFTOKEN=11242346>>, (pristupano: 20.05.2005.)
81. Pearce, J., A., Robinson, R., B.: *Strategic Management: Formulation, implementation & control*, McGraw-Hill/Irwin, Tenth Edition, 2007., New York
82. Poh, K., L., Ang, B., W.: Transportation fuels and policy for Singapore: An AHP planning approach, *Computers and Industrial Engineering* 37 (1999), pp. 507–525., 1999.
83. Rosenberg, M., J.: *E-LEARNING, Strategies for Delivering Knowledge in the Digital Age*, McGraw-Hill, 2001.
84. Saaty, R., William, A., *Super Decisions Software*, Creative Decisions Foundation, academic use <<http://www.superdecisions.com>>, 2005.
85. Saaty, T., L.: *The Analytic Network Process: Decision Making with Dependence and Feedback*, RWS Publications, 1996., completely revised and published 2001.
86. Saaty, T., L.: Time dependent decision-making; dynamic priorities in the AHP/ANP: Generalizing from points to functions and from real to complex variables, *Mathematical and Computer Modelling*, Volume 46, Issues 7-8, October 2007, pp. 860-891, 2007.
87. Saaty, T., L.: A scaling method for priorities in hierarchical structures. *Journal of Mathematical Psychology* 15 (3), pp. 234–281, 1977.
88. Saaty, T. L.: *Multicriteria Decision Making: The Analytic Hierarchy Process*, RWS Publications, 4922 Ellsworth Ave., Pittsburgh, PA 15213, 1980.
89. Saaty, T., L., Kearns, P., K.: *Analytical Planning, The Organization of Systems, The Analytic Hierarchy Process Series, Vol. IV*, RWS Publications, 1991.
90. Saaty, T., L., Ozdemir, M.: *The Encyclicon; a Dictionary of Applications of Decision Making with Dependence and Feedback based on the Analytic Network Process*, RWS Publications, 2005a.
91. Saaty, T., L., Cillo., B.: *The Encyclicon; A Dictionary of Complex Decisions Using the Analytic Network Process, Volume 2*, RWS Publications, Pittsburgh, 2008.
92. Saaty, T., L.: Decision Making – The Analytic Hierarchy and Network Processes (AHP/ANP), *Journal of Systems Science and Systems Engineering*, Vol. 13, No. 1, March, 2004.

93. Saaty, T., L.: The Analytic Network Process (ANP) for Decision Making and Forecasting with Dependence and Feedback, 2005b.
94. Saaty, T., L.: Theory and Applications of the Analytic Network Process: Decision Making with Benefits, Opportunities, Costs, and Risks, RWS Publications, Pittsburgh, 2005c.
95. Saaty, T., L., Peniwati, K.: Group Decision Making: Drawing Out and Reconciling Differences, RWS Publications, Pittsburgh, 2008.
96. Saaty, T., L., Shang, J. S.: Group Decision Making: Head-Count versus Intensity of Preference, *Socio-Economic Planning Sciences* 41, pp. 22-37, 2007.
97. Saaty, T., L., Vargas, L., G.: Decision Making with the Analytic Network Process Economic, Political, Social and Technological Applications with Benefits, Opportunities, Costs and Risks, Springer US, USA, 2006.
98. Saaty, T., L.: Online Course Materials: Decision Making in Complex Environment, Katz Graduate School of Business, University of Pittsburgh, Pittsburgh, SAD, 2008.
99. Saaty, T., L., Vargas, L., G.: The Logic of Priorities, The Analytic Hierarchy Process Series, Vol. III, RWS Publications, USA, 1991.
100. Saaty, T., L., Peniwati, K., Shang, J., S.: The analytic hierarchy process and human resource allocation: Half the story, *Mathematical and Computer Modelling*, Volume 46, Issues 7-8, October 2007, pp. 1041-1053
101. Salo, A., A., Hamalainen, R., P.: On the measurement of preferences in the Analytic Hierarchy Process, *Journal of Multiple Criteria Decision Analysis* 6, pp. 309-319, 1999.
102. Salomon, V., A., P., Whitaker, R.: Decision-Making Considering Dependence Relations for the Improvement of Production Management, *Brazilian Journal of Operations & Production Management*, Volume 4, Number 2, 2007.
103. Schniederjans, M., J., Wilson, R., L.: Using the analytic hierarchy process and goal programming for information system project selection, *Information and Management* 20 (1991), pp. 333-342., 1991.
104. Schoemaker, P., J., and Waid, C., C.: An experimental comparison of different approaches to determining weights in additive utility models, *Management Science*, 28(2), 182-196, 1982.
105. Schoner, B., Wedley, W., C.: Ambiguous criteria weights in AHP: consequences and solutions, *Decision Sciences* 20, pp. 462-475, 1989.
106. Schoner, B., Wedley, W., C., Choo, E., C.: A unified approach to AHP with linking pins, *European Journal of Operational Research* 66 (3), pp. 291-304, 1993.
107. Shinn Sun: Base closure: An application of the analytic hierarchy process, *INFOR*, Vol. 39, no. 1, Feb. 2001., <http://findarticles.com/p/articles/mi_qa3661/is_200102/ai_n8938983>, (pristupano: 10.3.2006.)
108. Smith, J.: Fro flowers to palms: 40 yers of policy for online learning, *ALT-J, Rsearch in Learning Technology*, 13 (2), 2005., p. 93-108

109. Spanjol, Z., Segotic, K., Jazbec, A., Hitrec, V.: Some factors concerning the issue of forest fires in the Mediterranean part of the Republic of Croatia, *Ekologia-Bratislava*, Volume 22, Issue 3, pp. 284-291, 2003.
110. Strategija e-učenja Sveučilišta u Zagrebu 2007. - 2010., svibanj 2007., <http://www.unizg.hr/fileadmin/rektorat/dokumenti/eucenje_strategija/E-ucenje-UniZG-Pov-Strategija-za-Javnu-Raspravu.pdf>
111. Su, X., Chen, Y., Hipel, K., W., Kilgour, D., M.: Comparison of the Analytic Network Process and the Graph Model for Conflict Resolution, *Journal of Systems Science and Systems Engineering* 14 (3), pp. 308-325, 2005.
112. Super Decisions Software for Decision-Making, Creative Decisions Foundation, Pittsburgh, <<http://www.superdecisions.com>>, (pristupano: 10.02.2006.)
113. Ta, H., P., Har, K., Y.: A study of bank selection decisions in Singapore using the analytical hierarchy process, *International Journal of Bank Marketing* 18 (2000) (4), pp. 170–180., 2000.
114. Tepeš, B.: Deskriptivna statistika, Filozofski fakultet, 2004., <<http://www.ffzg.hr/infoz/>>, (pristupano: 01.12.2006.).
115. Tipurić, D., Markulin, G.: Strateški savezi: suradnjom poduzeća do konkurentske prednosti, *Sinergija*, 2002., Zagreb
116. Triantaphyllou, E.: *Multi-Criteria Decision Making Methods: A Comparative Study*, Kluwer Academic Publishers, Dordrecht, The Netherlands, 2000.
117. Tzeng, G., Teng, M., Chen, J., Opricovic, S.: Multicriteria selection for a restaurant location in Taipei, *International Journal of Hospitality Management* 21 (2002), pp. 171–187., 2002.
118. Vaidya, O., S., Kumar, S.: Analytic hierarchy process: An overview of applications, *European Journal of Operational Research*, 169 (2006) pp. 1–29, 2006.
119. Weck, M., Klocke, F., Schell, H., Rüenauer, E.: Evaluating alternative production cycles using the extended fuzzy AHP method, *European Journal of Operational Research* 100 (1997), pp. 351–366., 1997.
120. Wills, S., Yetton, P.: *Strategy and Information Technology. Managing the introduction of technology in the delivery and administration of higher education*, Canberra, Evaluations and Investigations Programme, Department of Employment, Education, Training and Youth Affairs, DEST, 1997.
121. Wijnmalen, D., J., D.: Analysis of benefits, opportunities, costs, and risks (BOCR) with the AHP–ANP: A critical validation, *Mathematical and Computer Modelling*, Volume 46, Issues 7-8, October 2007, pp. 892-905
122. Whitaker, R.: Validation examples of the Analytic Hierarchy Process and Analytic Network Process, *Mathematical and Computer Modelling*, Volume 46, Issues 7-8, October 2007, pp. 840-859

123. Whitaker, R.: Criticisms of the Analytic Hierarchy Process: Why they often make no sense, *Mathematical and Computer Modelling*, Volume 46, Issues 7-8, October 2007, pp. 948-961
124. Wolfslehner, B., Vacick, H., Lexer, M., J.: Application of the Analytic Network Process in Multi-Criteria Analysis of Sustainable Forest Management, *Forest Ecology and Management* 207, pp. 157-170, 2005.
125. Young, S., McSporran, M.: Facilitating Successful Online Computing Courses While Minimising Extra Tutor Workload, *Proceedings of ACE 2004*, Volume 30, CRPIT '04 <<http://portal.acm.org/results.cfm?coll=Portal&dl=ACM&CFID=50988184&CFTOKEN=11242346>>, (pristupano: 15.05.2005.)
126. Zelenika, R.: Metodologija i tehnologija izrade znanstvenog i stručnog djela, EF u Rijeci, Rijeka, 1998.
127. Zemsky, R., Massy, W., F.: Thwarted innovation, what happened to e-learning and why, University of Pennsylvania, Weatherstation Project of the Learning Alliance, 2004.
128. Žugaj, M., Dumičić, K., Dušak, V.: Temelji znanstvenoistraživačkog rada, Fakultet organizacije i informatike Varaždin, Varaždin, 2006.
129. ...:CARNet, Hrvatska akademska i istraživačka mreža, <<http://www.carnet.hr/>>, (pristupano: 10.01.2006.)
130. ...: Coimbra group (2002), European Union Policies and Strategic Change for eLearning in Universities, Report of the project "Higher Education Consultation in Technologies of Information and Communication"(HECTIC), <<http://www.coimbra-group.be>>, (pristupano:15.05.2006.)
131. ...: Cambridge strategy of learning, <<http://www.camcitypct.nhs.uk/>>, (pristupano: 29.1.2006.)
132. ...: Commission of the European Communities CEC: eLearning Action Plan, Communication from the commission to the council and the european parliament, Brussels, 28.3.2001, COM (2001)172 final, 2001., <http://www.ntua.gr/dep/old/International/Europe/com2001_0172en01.pdf>, (pristupano:15.05.2006.)
133. ...:Decision Lens Software: <<http://www.decisionlens.com>>, For more information contact Decision Lens™, (pristupano: 20.8.2007.)
134. ...: Edupoint edukacijski centar, CARNet, <http://www.carnet.hr/edupoint/o_nama>, (pristupano:10.01.2006)
135. ...:E-learning akademija, CARNet , <<http://www.carnet.hr/ela/>>, (pristupano:10.01.2006)
136. ...: E-Learning Strategy - Cardiff University, <<http://www.cardiff.ac.uk/>>, (pristupano: 3.2.2006.)
137. ...:Teaching and Learning strategy – University of Durham <<http://www.dur.ac.uk/teachingandlearning.handbook/7-5-1.pdf>>, (pristupano:02.02.2006.)
138. ...:E-Learning Strategy - University of Dundee

- <http://www.somis.dundee.ac.uk/academic/e_learning_strat.htm>, (VERSIONS: JANUARY 2004), (pristupano:30.01.2006.)
139. E-learning Strategy - Edinburgh University 2004-7, <http://www.e-learning.ed.ac.uk/>, (pristupano: 3.2.2006.)
 140.E-Learning Strategy - University of Hull
<http://www.hull.ac.uk/elearning/documents/eLearning_Strategy_Part1v2.pdf>, (pristupano:29.01.2006.)
 141.E-Learning Strategy - University of Reading,
<http://www.rdg.ac.uk/Handbooks/Teaching_and_Learning/elearning_strategy.pdf>,(pristupano:30.01.2006.)
 142.: E-Learning Strategy - Imperial College, London, < <http://www.imperial.ac.uk>>, (pristupano: 2.2.2006.)
 143.: E-learning Strategy Discussion Document - Massey University,
<<http://quality.massey.ac.nz/>>, (pristupano: 1.2.2006.)
 144.: E-Learning Strategy - Queen's University Belfast, <<http://www.qub.ac.uk/>>, (pristupano: 1.2.2006.)
 145.: E-Learning Strategy Consultation - Sussex University, <<http://www.sussex.ac.uk/>>, (pristupano: 1.2.2006.)
 146.:E-Learning Strategy - University College Worcester,
<<http://www2.worc.ac.uk/elearning/docs/elearningactionplan.pdf>>, (pristupano:29.01.2006.)
 147. E-Learning Strategy - University of Ulster
<www.ulster.ac.uk/academicoffice/download/Policies/E-Learning%20Strategy.doc>, (pristupano:29.01.2006.)
 148.: E-learning strategy – Warwick University, <<http://www2.warwick.ac.uk/>>, (pristupano: 1.2.2006.)
 149.: European University Association EUA, <<http://www.eua.be/eua/index.jsp>>, (pristupano: 10.2.2006.)
 150.: Expert Choice, Quick Start Guide and Tutorials, priručnik programskog alata
 151.: Expert Choice Software: < <http://www.expertchoice.com/> >, TeamEC2000 (2000.)
For more information contact Expert Choice, (pristupano: 20.5.2005.)
 152.: HEFCE (2005): HEFCE strategy for e-learning, London, Higher Education Funding Council for England, London, 2005.
 153.: Illinois Online Network: Strengths and Weaknesses of Online Learning, Illinois Online Network and the Board of Trustees of the University of Illinois, 2003.
<<http://www.ion.uillinois.edu/resources/tutorials/overview/strengthAndWeak.asp>>, (pristupano: 25.03.2005.)
 154.: International Conference on Analytic Hierarchy Process (ISAHP), <www.isahp.org>, (pristupano: 10.8.2007.)
 155.: Jezgra za međunarodne projekte, Fakultet organizacije i informatike
<<http://www.projekti.hr/>>, (pristupano: 15.5.2008.)

156.: Katz Graduate School of Business, University of Pittsburgh,
<<http://www.business.pitt.edu/katz/>>, (pristupano: 10.1.2008.)
157.: Lisabonska strategija za povećanje konkurentnosti Europske unije, Zaključci
Europskog vijeća u Lisabonu, 23. - 24. ožujak 2000.,
www.mvpei.hr/ei/download/2004/07/05/Lisabonska_strategija-za_web.doc
158.: Observatory of Borderless Higher Education, <<http://www.obhe.ac.uk/>>, (pristupano:
1.2.2006.)
159.: Odluka Rektorskog Zbora o nužnim uvjetima za ocjenu nastavne i stručne djelatnosti u
postupku izbora u znanstveno-nastavna zvanja,
<<http://www.nn.hr/clanci/sluzbeno/2005/2394.htm>>, (pristupano: 20.06.2008.)
160.: OECD (Organisation for Economic Co-operation and Development), E-learning in
Tertiary Education, Where do we stand?, Paris, 2005.
161.: Oxford Brookes' e-learning strategy 2002 – 2005
<<https://mw.brookes.ac.uk/display/c4e1/Previous+strategies>>, (pristupano: 25.05.2006.)
162.: Pentagon, U.S. Department of Defense, <<http://pentagon.afis.osd.mil/>>, (pristupano:
20.03.2008.)
163.: Plan razvoja sustava odgoja i obrazovanja 2005. – 2010.; Republika Hrvatska
Ministarstvo znanosti, obrazovanja i športa, Zagreb, rujan
2005., <<http://public.mzos.hr/fgs.axd?id=10078>>, (pristupano: 16.10.2007.)
164.: Referalni centri za e-obrazovanje, CARNet,
<<http://www.carnet.hr/referalni/obrazovni>>, (pristupano: 10.01.2006.)
165.: Referalni centar za upravljanje kvalitetom u institucijama visokog školstva, Fakultet
organizacije i informatike, <<http://www.foi.hr/kvaliteta/linkovi.html>>, (pristupano:
15.3.2006)
166.: Razvojna strategija Sveučilišta u Zagrebu - I S K O R A K 2001
<http://rektorat.unizg.hr/fileadmin/rektorat/dokumenti/iskorak2001/razvojna_strategija_svucilista_u_zagrebu.pdf>, (pristupano: 20.04.2006.)
167.: Science Citation Index Expanded™, <<http://scientific.thomson.com/products/scie/>>,
(pristupano: 10.06.2008)
168.: Standardizacija i valorizacija digitalnih obrazovnih materijala, CARNet, svibanj 2005,
<http://www.carnet.hr/crepozitorij/standardizacija_i_valorizacija.pdf?CARNetweb=a7f738e1cd95de5b4eb05cce75f88002>, (pristupano: 20.03.2006.)
169.: Standards and Guidelines for Quality Assurance in the European Higher Education
Area, European Association for Quality Assurance in Higher Education, Helsinki, Finland
2005,
<http://eu2006.bmbwk.gv.at/veranst/qual/standards_and_guidelines_for_qa_in_the_ehea.pdf
>, (pristupano: 10.01.2006.)
170.: Strategija uvođenja e-učenja na Sveučilištu u Rijeci 2006-2010, Listopad 2006,
<http://www.uniri.hr/hr/propisi_i_dokumenti/Strategija_uvodjenja_e-ucenja_UNIRI.pdf>,
(pristupano: 10.12.2006.)

171. ...: Strategija e-učenja 2007. – 2010. Sveučilišta u Zagrebu, <http://www.unizg.hr/fileadmin/rektorat/dokumenti/eucenje_strategija/Sveuciliste_u_Zagrebu_Strategija_e_ucenja_Senat_v1.pdf>, (pristupano: 18.06.2007.)
172. ...: Super Decisions Software: <<http://www.superdecisions.com>>, For more information contact Creative Decisions Foundation, (pristupano: 20.1.2006.)
173. ...: Sveučilišni računski centar, SRCE, Sveučilište u Zagrebu, <<http://www.srce.hr/>>, (pristupano: 10.1.2006.)
174. ...: Tempus EQIBELT, Education Quality Improvement by E-Learning Technology, <<http://eqibelt.srce.hr>>, (pristupano: 16.1.2006.)
175. ...: Tutorial on Complex Decision Models (ANP), <<http://www.superdecisions.com/~saaty/Software%20Manuals%20and%20Tutorials/Tutorial%20for%20Building%20Network%20Models.doc>>, (pristupano: 20.05.2007.)

Popis priloga

Prilog 1. Popis ispitanika u istraživanju – po klasterima	I
Prilog 2. Objašnjenja kriterija i podkriterija priložena uz anketu	V
Prilog 3. Anketni upitnik	XI
Prilog 4. Statistička obrada ankete - pokazatelji po varijablama	XV
Prilog 5. Postupak i rezultati grupnog odlučivanja AHP metodom – izvještaj generiran od strane alata TeamEC200	XLVII
Prilog 6. Neponderirane i ponderirane supermatrice dobivene testiranjem ANP modela	LXXIX
Prilog 7. Strategija e-učenja 2007. – 2010., Sveučilište u Zagrebu	LXXXII
Prilog 8. Strategija e-učenja Fakulteta organizacije i informatike	CI