

SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Andrea Arbula Blecich

**VREDNOVANJE EFIKASNOSTI I
EFEKTIVNOSTI VISOKOOBRAZOVNIH
INSTITUCIJA EKONOMSKOG
USMJERENJA U FUNKCIJI POVEĆANJA
NJIHOVE KVALITETE**

DOKTORSKA DISERTACIJA

Rijeka, 2015.

SVEUČILIŠTE U RIJECI
EKONOMSKI FAKULTET

Andrea Arbula Blecich

**VREDNOVANJE EFIKASNOSTI I
EFEKTIVNOSTI VISOKOOBRAZOVNIH
INSTITUCIJA EKONOMSKOG
USMJERENJA U FUNKCIJI POVEĆANJA
NJIHOVE KVALITETE**

DOKTORSKA DISERTACIJA

Mentor: Prof. dr. sc. Mira Dimitrić

Rijeka, 2015.

UNIVERSITY OF RIJEKA
FACULTY OF ECONOMICS

Andrea Arbula Blecich

**EVALUATION OF EFFICIENCY AND
EFFECTIVENESS OF HIGHER
EDUCATION INSTITUTIONS FOR
QUALITY ENHANCEMENT**

DOCTORAL THESIS

Rijeka, 2015.

Mentorica rada: prof. dr. sc. Mira Dimitrić, Ekonomski fakultet Rijeka

Doktorski rad obranjen je dana 15. prosinca 2015. godine na Ekonomskom fakultetu u Rijeci, Sveučilište u Rijeci, pred povjerenstvom u sastavu:

1. Prof. dr. sc. Davor Vašiček, predsjednik povjerenstva, Ekonomski fakultet Rijeka
2. Prof. dr. sc. Mira Dimitrić, mentorica i članica, Ekonomski fakultet Rijeka
3. Prof. dr. sc. Lorena Mošnja – Škare, članica, Fakultet ekonomije i turizma "Dr. Mijo Mirković", Pula

Rijeka, 15. prosinca 2015.

PREDGOVOR

Ovom prigodom željela bih se zahvaliti svim osobama koje su pridonijele izradi ove doktorske disertacije. Prije svega, iskrenu i posebnu zahvalnost dugujem mentorici, prof. dr. sc. Miri Dimitrić koja, osim što mi je pružila priliku za rad na fakultetu, svojim je usmjeravanjem, sugestijama i iznimnom podrškom omogućila izradu ovog rada.

Također, zahvaljujem i prof. dr. sc. Davoru Vašičeku koji je svojim sugestijama i nesebičnom pomoći pridonio nastajanju ovog rada.

Zahvaljujem svim prijateljima i kolegama koji su mi pružali podršku i svojim komentarima doprinijeli u razvoju ideja prezentiranih u doktorskoj disertaciji.

Iznimnu zahvalnost izražavam svojim roditeljima, Jadranki i Đinu, na bezrezervnoj podršci tijekom cijelog školovanja i života te suprugu Paolu na dugogodišnjoj potpori, razumijevanju i strpljenju. Bili ste mi veliki oslonac i na ovom putovanju.

SAŽETAK

Ispred visokoobrazovnih institucija, kako svijeta, tako i Europske unije stavljaju se sve veći zahtjevi po pitanju kvalitete kojima Republika Hrvatska, kao članica EU također mora udovoljiti. Iako se kvaliteta stavlja na središnje mjesto, ona je sa znanstvenog aspekta na području Hrvatske i zemalja u regiji nedovoljno istražena. U ovoj doktorskoj disertaciji kvaliteta je istražena vrednovanjem efikasnosti i efektivnosti kao njezine dvije temeljne odrednice, a istraživanje je provedeno putem dva postavljena modela, empirijskog za određivanje efikasnosti i teorijskog za određivanje efektivnosti.

U doktorskoj disertaciji empirijskim modelom vrednuje se relativna efikasnost visokoobrazovnih institucija ekonomskog usmjerenja. Rezultatima modela dobio se uvid u rezultate relativne efikasnosti promatranih institucija po specifičnim područjima njihova djelovanja te bitne čimbenike koji na nju djeluju. Subjekti vrednovanja su 31 javna i privatna visokoobrazovna institucija ekonomskog usmjerenja (fakulteti, odjeli sveučilišta, odjeli veleučilišta i visoke škole) s područja Hrvatske, Slovenije i Bosne i Hercegovine. Temeljem spoznaja dobivenih iz analize moći će se djelovati na izvore neefikasnosti svake pojedine institucije, kao što će se moći utvrditi i čimbenici bitni za pripadnost pojedinom klasteru formiranom temeljem ostvarenih rezultata relativne efikasnosti.

Analiza je provedena u tri međusobno povezane faze. U prvoj fazi su postavljena i testirana četiri modela za koja se analizom omeđivanja podataka utvrdio rezultat relativne efikasnosti visokoobrazovnih institucija ekonomskog usmjerenja. Tri modela vrednuju relativnu efikasnost promatranih institucija kroz tri temeljna područja njihova djelovanja (nastavna, znanstvena i međunarodna djelatnost), a četvrti model vrednuje relativnu efikasnost ukupnog poslovanja. Utvrđeni su izvori neefikasnosti za svaki pojedini model i predložene smjernice za potencijalna poboljšanja kojima bi se isti otklonili. Nakon prve faze provedena je druga faza u kojoj su klaster analizom, temeljem rezultata relativne efikasnosti svakog pojedinog područja, visokoobrazovne institucije podijeljene u dvije skupine, odnosno klastere. Nakon druge faze pristupilo se trećoj fazi u kojoj su univarijantnom binarnom logističkom regresijom identificirani ključni čimbenici pripadnosti pojedinom klasteru te su temeljem istih utvrđene vjerojatnosti prelaska u povoljniji klaster. Na ovaj način postavljen model pruža odmak od standardnih modela jer omogućuje sveobuhvatan i generalan uvid u identificiranje čimbenika bitnih za pripadnost određenom klasteru formiranom temeljem rezultata relativne efikasnosti svakog područja djelovanja visokoobrazovnih institucija.

Pored empirijskog modela postavljen je i teorijski okvir za vrednovanje efektivnosti visokoobrazovnih institucija. Efektivnost institucije predstavlja proces kojim institucija definira koliko uspješno je ostvarila zadanu misiju. Pritom je ispravno definiranje misije kao i samih ishoda koje je potrebno ostvariti ključno za ostvarivanje više razine efektivnosti. Ukoliko se koncept institucionalne efektivnosti primijeni na primjeru visokoobrazovnih institucija, važno je prije svega utvrditi što je bitno, definirati ishode, pratiti ih i koristiti rezultate za ostvarivanje efektivnijeg poslovanja. S obzirom da je nužan preduvjet ostvarivanja efektivnosti ostvarivanje efikasnosti iz razdoblja u razdoblje, pri definiranju ciljeva i provođenju radnji za njihovo ostvarenje treba u obzir uzeti rezultate relativne efikasnosti dobivene empirijskim modelom vrednovanja, kao i prijedloge za njezino poboljšanje.

Iako su modeli konstruirani i primijenjeni konkretno na visokoobrazovnim institucijama ekonomskog usmjerenja, uz određene modifikacije, mogli bi se primijeniti i na visokoobrazovnim institucijama drugih usmjerenja, kako u Hrvatskoj, tako i šire.

ABSTRACT

The higher education institutions in the European Union are facing more and more challenging demands regarding quality achievement. Croatia, as a EU member state, must comply to this demands. Although quality is crucial for higher education institutions, it is not sufficiently studied in Croatia and countries of the region, from a scientific point of view. In this doctoral thesis, quality of higher education is studied through the evaluation of its two basic principles: efficiency and effectiveness. The research is carried out with two models: empirical to assess the efficiency and theoretical to assess the effectiveness.

The empirical model evaluates the relative efficiency of higher education institutions of economic orientation. The model results offered an overview about the relative efficiency of the observed institutions according to their areas of activities and factors affecting it. The subjects of evaluation are 31 public and private higher education institutions of economic affiliation (faculties, university departments, departments of polytechnics and private colleges) from Croatia, Slovenia and Bosnia and Herzegovina. Based on the obtained results it will be possible to influence the sources of inefficiency in each of the observed institution. Also, from results of relative efficiency, it will be possible to identify the factors that determine the position of the institutions in the cluster.

The analysis was carried out through three phases. In the first phase, four models are tested using data envelopment analysis. The results of the first phase are relative efficiency scores for higher education institutions of economic orientation. In the first phase, three models evaluate the relative efficiency of the observed institutions within three main areas of their activities (teaching, research and international activity), while the fourth model evaluates the relative efficiency of the overall business. Sources of inefficiency are identified for each model and guidelines for the potential improvement are suggested. In the second phase, cluster analysis was used. Based on the results of relative efficiency for each area of activity, higher education institutions are divided into two clusters. In the third phase, univariate binary logistic regression was used to determine the key association factors of a particular cluster. Based on these factors, the probability of transition to a more favorable cluster was defined. Unlike standard models, the empirical model gives different points of view as it offers both, a comprehensive and a general insight into identifying the essential factors for positioning inside a specific cluster. The clusters are based on results of relative efficiency for different areas of activities of the observed higher education institutions.

In addition to the empirical model, a theoretical framework for evaluating the effectiveness of higher education institutions was presented. The effectiveness of an institution is the process of determining how successfully the institution was in achieving its mission. To achieve a higher level of effectiveness, it is important to properly define the mission and the outcomes. If the concept of institutional effectiveness is applied on higher education institutions, it is important to decide what is important, to define the outcomes, to monitor them and to use the results to achieve a more effective activity. Given that the prerequisite for achieving effectiveness is having an efficient activity over an observed period, the results of relative efficiency should be taken into account when defining the objectives and the actions for its achievement.

Although the empirical and the theoretical model are designed and applied specifically to higher education institutions of economic orientation, with certain modifications, they could be applied to higher education institutions of different orientation, both in Croatia and in other countries.

Ključne riječi

Efikasnost

Efektivnost

Kvaliteta

Visokoobrazovne institucije ekonomskog usmjerenja

Troškovno računovodstvo u javnome sektoru

Keywords

Efficiency

Effectiveness

Quality

Higher education institutions of economic orientation

Cost accounting in public sector

SADRŽAJ:

Predgovor	IV
Sažetak.....	V
Abstract	VI
Ključne riječi.....	VII
Keywords.....	VII
1. UVOD	1
1.1. PROBLEM, PREDMET I OBJEKT ISTRAŽIVANJA.....	1
1.2. ZNANSTVENA HIPOTEZA I POMOĆNE HIPOTEZE	3
1.3. SVRHA I CILJEVI ISTRAŽIVANJA.....	5
1.4. OCJENA DOSADAŠNJIH ISTRAŽIVANJA	6
1.5. ZNANSTVENE METODE.....	17
1.6. STRUKTURA RADA	17
2. OPĆE I RAČUNOVODSTVENE ODREDNICE VISOKIH UČILIŠTA JAVNOGA SEKTORA.....	20
2.1. RELEVANTNE ZNAČAJKE JAVNOGA SEKTORA U SEGMENTU VISOKOG OBRAZOVANJA	21
2.2. OSNIVANJE I ORGANIZACIJA VISOKIH UČILIŠTA U REPUBLICI HRVATSKOJ	25
2.2.1. Pojam i ustroj visokih učilišta u Republici Hrvatskoj	26
2.2.2. Oblici organizacije visokih učilišta u Republici Hrvatskoj	27
2.3. FINANCIRANJE VISOKIH UČILIŠTA JAVNOGA SEKTORA	28
2.3.1. Financiranje visokih učilišta javnoga sektora u zemljama Europe.....	31
2.3.2. Financiranje visokih učilišta javnoga sektora u Republici Hrvatskoj.....	35
2.3.3. Financiranje znanstvene djelatnosti u Europskoj uniji i Republici Hrvatskoj.....	42

2.4. PRORAČUNSKO RAČUNOVODSTVO U SEGMENTU VISOKOG OBRAZOVANJA	50
2.4.1. Osnovne odrednice proračunskog računovodstva u segmentu visokog obrazovanja.....	52
2.4.2. Financijsko izvješćivanje proračunskih korisnika u visokom obrazovanju.....	57
2.5. VISOKO OBRAZOVANJE KAO DIO DRUŠTVENO ODGOVORNOG RAČUNOVODSTVA.....	60
3. TEMELJNE ODREDNICE VISOKOG OBRAZOVANJA REPUBLIKE HRVATSKE I ZEMALJA REGIJE S POSEBNIM OSVRTOM NA VISOKO OBRAZOVNE INSTITUCIJE EKONOMSKOG USMJERENJA	69
3.1. ULOGA VISOKOG OBRAZOVANJA U GOSPODARSTVU DRŽAVE I DRUŠTVU OPĆENITO	69
3.2. REFORMA VISOKOG OBRAZOVANJA U EUROPI U FUNKCIJI STVARANJA NJEGOVE KVALITETE.....	72
3.3. VISOKO OBRAZOVANJE U REPUBLICI HRVATSKOJ S NAGLASKOM NA VISOKO OBRAZOVNE INSTITUCIJE EKONOMSKOG USMJERENJA.....	74
3.4. VISOKO OBRAZOVANJE U DRŽAVAMA REGIJE	85
3.5. EUROPSKI I HRVATSKI KVALIFIKACIJSKI OKVIR KAO SREDSTVO OSIGURAVANJA TRANSPARENTNOSTI I USPOREDNOSTI KVALIFIKACIJA ..	88
4. KONCEPT EFIKASNOSTI I EFEKTIVNOSTI KAO ODREDNICA KVALITETE VISOKOG OBRAZOVANJA.....	92
4.1. DEFINIRANJE KVALITETE VISOKOG OBRAZOVANJA.....	93
4.2. DEFINIRANJE EFIKASNOSTI U VISOKOM OBRAZOVANJU	100
4.3. DEFINIRANJE EFEKTIVNOSTI U VISOKOM OBRAZOVANJU.....	105
5. METODOLOŠKI OKVIR ZA MODELIRANJE VREDNOVANJA VISOKO OBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA	109
5.1. ANALIZA OMEĐIVANJA PODATAKA KAO METODA VREDNOVANJA RELATIVNE EFIKASNOSTI U INSTITUCIJAMA JAVNOG SEKTORA	109

5.2. KLASTER ANALIZA KAO METODA IDENTIFICIRANJA I KLASIFICIRANJA SKUPINE RAZLIČITIH OBJEKATA	126
5.3. BINARNA LOGISTIČKA REGRESIJA KAO MJERA IDENTIFIKACIJE KLJUČNIH ČIMBENIKA PRIPADNOSTI POJEDINOJ SKUPINI	131
6. EMPIRIJSKI MODEL VREDNOVANJA RELATIVNE EFIKASNOSTI VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA REPUBLIKE HRVATSKE I DRŽAVA REGIJE	137
6.1. DEFINIRANJE I PRETPOSTAVKE MODELA	137
6.2. PRVA FAZA MODELA – VREDNOVANJE RELATIVNE EFIKASNOSTI VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA ANALIZOM OMEĐIVANJA PODATAKA	141
6.2.1. Odabir inputa i outputa	141
6.2.2. Testiranje modela vrednovanja relativne efikasnosti javnih ekonomskih fakulteta primjenom analize omeđivanja podataka	151
6.3. DRUGA FAZA MODELA – GRUPIRANJE DONOSIOCA ODLUKE PRIMJENOM KLASTER ANALIZE	160
6.4. TREĆA FAZA MODELA – IDENTIFICIRANJE KLJUČNIH ČIMBENIKA PRIPADNOSTI POJEDINOM KLASTERU PRIMJENOM BINARNE LOGISTIČKE REGRESIJE	164
6.5. ALTERNATIVNI MODEL VREDNOVANJA RELATIVNE EFIKASNOSTI VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA.....	168
6.6. UČINCI PRIMJENE MODELA VREDNOVANJA RELATIVNE EFIKASNOSTI VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA.....	175
7. KVALITATIVNI MODEL VREDNOVANJA EFEKTIVNOSTI VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA	178
7.1. HIJERARHIJA CILJEVA KAO OKVIR KVALITATIVNOG MODELA VREDNOVANJA EFEKTIVNOSTI.....	178
7.2. FAZE MODELA VREDNOVANJA EFEKTIVNOSTI	180
8. ZAKLJUČAK.....	183

LITERATURA	190
POPIS TABLICA.....	213
POPIS GRAFIKONA	215
POPIS SHEMA.....	216
KAZALO KRATICA.....	217
PRILOG 1:.....	220
PRILOG 2:.....	222

1. UVOD

Obrazovanje je jedno od ključnih područja interesa svake zemlje jer o njemu ovisi kvaliteta njezine buduće radne snage. Razina razvijenosti obrazovanja utječe na kvalitetu gospodarstva i obratno. Obrazovanje se, kao dio javnog sektora, većinski financira iz državnog proračuna. To predstavlja jedan od razloga zbog čega Republika Hrvatska, kao i ostale zemlje, moraju znati razinu njegove kvalitete te način kako utjecati na njezin rast.

U Strateškom planu Ministarstva znanosti, obrazovanja i sporta (MZOS) (2012b) navodi se da temeljem rezultata obavljene državne revizije iz 2011. godine, u Hrvatskoj postoji izražena „neefikasnost u organizaciji i neučinkovitost korištenja sredstva“ u ispunjenju misije te je integracija sveučilišta, koje MZOS ističe kao prioritet, još uvijek vrlo niska. Također se navodi kako je Zakon o znanstvenoj djelatnosti i visokom obrazovanju (ZZDVO) (2003) uveo promjenu u sustavu financiranja sveučilišta, ali unatoč tome nije došlo do povezivanja strateških ciljeva između samog sveučilišta i visokoga obrazovanja sa sustavom financiranja, niti je u potpunosti ostvarena integracija financiranja na razini sveučilišta.

Visoko obrazovne institucije ekonomskog usmjerenja, kako Hrvatske, tako i ostalih država u regiji spadaju u sektor visokog obrazovanja financiran od strane države. Aktualna svjetska ekonomska kriza suočava države sa snažnim pritiskom da novac koji ulože rezultira što boljim rezultatima. Zbog toga je nužno mjeriti efikasnost i efektivnost javnog sektora kako bi se područja dobrog poslovanja razdvojila od onih koja posluju loše te kako bi se primijenile odgovarajuće mjere za poboljšanje njihovih rezultata. Iako postoje napori, aktualno stanje kvalitete ekonomskih fakulteta u Republici Hrvatskoj i većini zemalja regije još uvijek nije u potpunosti zadovoljavajuće. Razlog tome je taj što se znanstveni interes za ovu temu počeo javljati tek posljednjih godina zbog čega na ovim područjima postoji značajan deficit po pitanju mjerenja i modeliranja kojima bi se kvantificirala efikasnost i efektivnost u području visokog obrazovanja. Ako potonji segment ne postoji, vrlo je teško djelovati na slabe dijelove organizacije s ciljem ostvarivanja boljih rezultata.

1.1. PROBLEM, PREDMET I OBJEKT ISTRAŽIVANJA

Prije definiranja znanstvenog problema valja naglasiti kako je u hrvatskom jeziku izražena nekonzistentnost u prijevodu i distinkciji pojmova efikasnosti i efektivnosti zbog čega često

dolazi do jezične nedoumice. Zbog toga različiti autori koriste različite pojmove u službi njihova prijevoda. Ovi pojmovi prisutni su, ne samo u području obrazovanja, nego i u drugim područjima, od energetike, medicine, pa sve do javne uprave. Pojmovi efikasnost i efektivnost su anglizmi pojmova „*efficiency* i *effectiveness*“. Tako npr. Popović i Vitezić (2009), Tintor (2009), Domović (2003), *efficiency* prevode kao „djelotvornost“, a *effectiveness* kao „učinkovitost“. Pri definiranju potonjeg pojma polazište im je učinak, odnosno efekt. Iako Sopek (2011) navodi iste prijevode kao prethodno spomenuti autori, zbog jezične nekonzistentnosti, u radu se ipak služi anglizmima „efikasnost“ i „efektivnost“. Vašiček, Budimir, Letinić (2007) pak za „*effectiveness*“ koriste izraz „djelotvornost“, a za „*efficiency*“ izraz „učinkovitost“ dok „*performance*“ prevode kao „uspješnost“ što je u potpunosti suprotno od prethodno spomenutih autora. Ima i jedinica literature u kojima nije jasno definirana pojmovna razlika između navedenih pojmova (Mihalić, 2012) te jedinica literature gdje se spominju pojmovi efikasnosti i efektivnosti, ali se također spominju i ostali srodni pojmovi poput učinkovitosti, djelotvornosti i uspješnosti bez jasne povezanosti između njih (Sveučilište u Zagrebu, 2012). Literatura broji i radove koji kombiniraju anglizam i hrvatski prijevod, npr. Slijepčević (2010) koristi pojmove „efikasnost“ i učinkovitost“ jednako kao i MZOS (2012b). Jedan od zanimljivijih primjera je „*Pojmovnik osnovnih termina i definicija u području osiguranja kvalitete u visokom obrazovanju*“ (AZVO, 2007) koji također koristi potonju kombinaciju anglizma i hrvatskog prijevoda. Iako je unutar Pojmovnika izvršena jasna distinkcija između navedenih pojmova, kroz objašnjavanje pojma „kvaliteta“, rečenica „...*efficiency of the processes at work*...“ je prevedena kao „...učinkovitost radnih procesa...“ čime se ispravnost jezičnog korištenja pojmova dovodi u pitanje. Ambrožič (1999), Mastilica (n.d.) pak „*efficiency*“ prevode kao „učinkovitost“, a *effectiveness* kao „uspješnost“

Unatoč nehomogenosti i varijacijama prijevoda, značenje ova dva pojma je u većini slučajeva jasno definirano i dosljedno korišteno, te će se ta pojmovna određenja koristiti i u ovom radu. Efikasnost je mjera koja prikazuje odnos utrošenih inputa i ostvarenih outputa dok je efektivnost mjera ostvarenosti ciljeva (više u poglavlju 4). U doktorskoj disertaciji će, kako bi se izbjegle moguće nedoumice, biti korišteni pojmovi efikasnost i efektivnost.

Uvažavajući spomenutu problematiku i konceptualna određenja, definira se **znanstveni problem istraživanja:**

Upravljanje kvalitetom javnoga sektora u Republici Hrvatskoj i mnogim državama regije često se vrši bez znanstvene potpore te odgovarajuće praktične primjene. Ono kao takvo

ne pruža potrebne informacije nužne državi i njezinim građanima o efikasnosti i efektivnosti rada institucija javnoga sektora koje bi oni, kao financijeri i korisnici javnih usluga morali imati. Spomenuta problematika izražena je i u sektoru visokog obrazovanja. To je razlog da se detaljno istraži, analizira, utvrdi i uspoređi relativna efikasnost visokoobrazovnih institucija Hrvatske i regije te predloži teorijski okvir vrednovanja efektivnosti čime bi se posljedično moglo utjecati na njihovu kvalitetu.

Iz znanstvenog problema istraživanja definira se **predmet znanstvenog istraživanja**:

Istražiti, analizirati i utvrditi relevantne čimbenike i značajke vrednovanja relativne efikasnosti visokoobrazovnih institucija ekonomskog obrazovanja u Republici Hrvatskoj i u državama regije te predložiti okvir za vrednovanje efektivnosti visokoobrazovnih institucija ekonomskog usmjerenja Hrvatske i onih u regiji kao izuzetno važnih preduvjeta unaprjeđenja njihove kvalitete.

Znanstveni problem i predmet istraživanja odnose se na četiri objekta znanstvenog istraživanja, a oni su: **efikasnost, efektivnost, kvaliteta te visokoobrazovne institucije ekonomskog usmjerenja u Republici Hrvatskoj i državama regije**

1.2. ZNANSTVENA HIPOTEZA I POMOĆNE HIPOTEZE

Sukladno određenom i definiranom znanstvenom problemu istraživanja, predmetu znanstvenog istraživanja i objektu znanstvenoga istraživanja postavljena je i **temeljna znanstvena hipoteza**:

Znanstveno utemeljenim spoznajama o poslovanju visokoobrazovnih institucija ekonomskog usmjerenja u Republici Hrvatskoj i državama regije, moguće je predložiti teorijski utemeljen i praktično primjenjiv model vrednovanja njihove relativne efikasnosti po pojedinim područjima poslovanja te izlučiti ključne čimbenike koji utječu na efikasnost visokoobrazovnih institucija ekonomskog usmjerenja. Modelom je moguće identificirati čimbenike koji određuju vjerojatnost ostvarivanja određene razine relativne efikasnosti. Također, moguće je predložiti teorijski utemeljen kvalitativni model

utvrđivanja efektivnosti čijom primjenom se posljedično omogućuje unaprjeđenje kvalitete.

Tako postavljena temeljna znanstvena hipoteza, implicira više **pomoćnih hipoteza**:

- **PH1:** Vrednovanje relativne efikasnosti visokog obrazovanja identificira dobro i loše poslovanje te ukazuje na razloge lošeg poslovanja. Djelovanjem na njih može se posljedično utjecati na unaprjeđenje kvalitete.
- **PH2:** Izabrani i testirani empirijski modeli vrednovanja ukazuju na potrebne aktivnosti za njihovu implementaciju.
- **PH3:** Postavljeni teorijski okvir za vrednovanje efektivnosti visokoobrazovnih institucija omogućuje uvid u proces unutarnjeg vrednovanja ishoda u funkciji ostvarivanja efektivnosti visokoobrazovnih institucija.

Temeljnu znanstvenu hipotezu i njezine pomoćne hipoteze podupiru brojni **argumenti**, a najvažniji su:

- Visoko obrazovanje u Republici Hrvatskoj i zemljama regije u većini je dio javnoga sektora. Novcem poreznih obveznika puni se proračun kojim se potom financiraju javne potrebe. Dio tih sredstava izdvaja se i za financiranje visokog obrazovanja zbog čega je nužno da porezni obveznici imaju uvid u što se ulaže njihov novac. Republika Hrvatska, kao i većina država regije ne vrednuje efikasnost svog visokoobrazovnog sustava zbog čega je vrlo teško sa sigurnošću odrediti slabe točke i djelovati na njihovo jačanje te stimulirati jake točke u sustavu.
- Sve je više izražena kompeticija između ustanova visokog obrazovanja u namjeri da privuku studente. S obzirom na porast mobilnosti studenata i mogućnosti studiranja na sve širem geografskom području, kvaliteta postaje jedna od presudnih stavki pri stvaranju interesa za studiranje na određenoj instituciji.
- Postizanje više razine kvalitete visokog obrazovanja utječe na rast kvalitete diplomiranih studenata koji imaju direktan utjecaj na rast i razvoj gospodarstva jedne države.
- Praksa razvijenih država pokazuje kontinuitet vrednovanja efikasnosti, kako visokoobrazovnih institucija, tako i cijeloga javnoga sektora pri čemu koriste

mnogobrojne metode i modele. Države koje dugi niz godina redovito vrednuju efikasnost svojeg visokoobrazovnog sustava poput Velike Britanije, su one kojima je on na samome vrhu kvalitete visokog obrazovanja u Europi i svijetu.

- Europska unija želi osigurati jedinstveni sustav visokog obrazovanja koji jamči minimalnu razinu kvalitete. U interesu je svake države, kako članica tako i onih koje se žele priključiti Europskoj uniji, da počnu primjenjivati propisane standarde s ciljem stvaranja zajedničkog visokoobrazovnog sustava.

1.3. SVRHA I CILJEVI ISTRAŽIVANJA

Imajući u vidu znanstveni problem, predmet i objekt istraživanja te znanstvenu i pomoćne hipoteze određeni su **svrha i ciljevi istraživanja**:

Svrha istraživanja je dokazati da se znanstveno utemeljenim vrednovanjem efikasnosti mogu identificirati i kvantificirati čimbenici relativne efikasnosti te time utjecati na njezino povećanje, kao i na otklanjanje izvora neefikasnosti. Svrha je i dokazati da se unutarnjim procedurama vrednovanja efektivnosti može utjecati na poboljšanje kvalitete poslovanja i stupnja dostizanja postavljenih ciljeva.

Cilj istraživanja je izraditi model vrednovanja relativne efikasnosti visokoobrazovnih institucija ekonomskog usmjerenja kojim će se identificirati i kvantificirati izvori neefikasnosti te utvrditi čimbenici koji određuju vjerojatnost ostvarivanja boljih rezultata relativne efikasnosti. Također, cilj je i predložiti kvalitativni model utvrđivanja efektivnosti visokoobrazovnih institucija ekonomskog usmjerenja.

Uz navedenu svrhu i ciljeve istraživanja, kako bi se riješio problem istraživanja i dokazala temeljna znanstvena i pomoćne hipoteze, potrebno je dati odgovore na mnoga pitanja od kojih su slijedeća najvažnija:

1. Koja su opće odrednice visokih učilišta javnoga sektora?
2. Koji su načini financiranja i alokacije troškova visokih učilišta javnoga sektora?

3. Koje su odrednice proračunskog računovodstva u segmentu visokog obrazovanja i kolika je važnost primjene troškovnog i upravljačkog računovodstva u visokom obrazovanju?
4. Koje su prednosti primjene koncepta društveno odgovornog računovodstva u javnom sektoru?
5. Koje su specifičnosti visokoobrazovnoga sustava i visokoobrazovnih institucija ekonomskog usmjerenja Republike Hrvatske i država regije?
6. Koje su novosti Bolonjskog u odnosu na Predbolonjski sustav?
7. Koja su važnija obilježja kvalitete visokoobrazovnog sustava?
8. Kolika je važnost vrednovanja efikasnosti i efektivnosti visokoobrazovnog sustava?
9. Kakvo je iskustvo država u svijetu u primjeni modela vrednovanja efikasnosti visokoobrazovnog sustava?
10. Koji su mogući modeli vrednovanja visokoobrazovnih institucija ekonomskog usmjerenja u Republici Hrvatskoj i u državama regije?
11. Koji su učinci primjene modela vrednovanja efikasnosti i efektivnosti javnih ekonomskih fakulteta u Republici Hrvatskoj i u državama regije?
12. Koje se aktivnosti trebaju provesti za implementaciju modela vrednovanja efektivnosti visokoobrazovnih institucija ekonomskog usmjerenja u Republici Hrvatskoj

1.4. OCJENA DOSADAŠNJIH ISTRAŽIVANJA

Vrednovanje relativne efikasnosti visokog obrazovanja u svjetskoj je literaturi u fokusu istraživanja dugi niz godina. Za spomenutu problematiku najčešće se koriste nestatističke metode koje se baziraju na procjeni granice efikasnosti. U njih se ubrajaju stohastička analiza granice (SFA) i analiza omeđivanja podataka (AOMP). SFA je stohastička parametrijska metoda koja a priori pretpostavlja oblik funkcije efikasnosti te koristi raspoložive podatke kako bi ekonometrijski procijenila parametre funkcije korištenjem cijelog seta subjekata vrednovanja (donosioca odluke –DO) (Meeusen, Van den Broeck (1977), Aigner, Lovell, Schmidt (1977)). SFA dopušta pretpostavku stohastičke veze između inputa i outputa te omogućuje pretpostavku

da odstupanja od granice efikasnosti nisu nužno odraz neefikasnosti nego šuma u podacima (eng. *noisy data* - beznačajni i besmisleni podaci koji se pojavljuju zajedno sa značajnim informacijama) (Bogetoft i Otto, 2011). SFA nije jednostavno primijeniti u uvjetima postojanja višestrukih inputa i outputa (moguće je u analizu uključiti svega jedan output) što predstavlja problem kod vrednovanja efikasnosti visokog obrazovanja. AOMP se, za razliku od SFA, ubraja u determinističke neparametrijske metode te koristi linearno (matematičko) programiranje za procjenu granice efikasnosti. Za razliku od SFA, kod AOMP postoji pretpostavka da ne postoji šum u podacima. AOMP se jednostavno nosi s višestrukim inputima i outputima koji karakteriziraju visoko obrazovanje te je to je jedan od ključnih razloga zašto se je isprofilirala se kao trenutno najprimjerenija i najkorištenija metoda u tom području vrednovanja.

Iako su istraživanja relativne efikasnosti visokog obrazovanja prisutna u velikom broju zemalja, najveći broj proveden je na području UK-a i SAD-a. Kao najčešće korištena metoda vrednovanja efikasnosti pokazala se AOMP te će, s obzirom da je ta metoda prvotno i namijenjena ovakvom tipu istraživanja, biti korištena i u ovoj doktorskoj disertaciji u prvoj fazi modela.

Cilj istraživanja relativne efikasnosti u visokom obrazovanju bio je utvrditi njezinu dostignutu razinu i utjecati na njezino povećanje što je 70 – tih godina dovelo do većeg broja radova na ovu temu, npr. Brovender (1974), Verry, Layard (1975), Tierney (1980). Spomenuta istraživanja pripadaju ranijoj fazi, a specifična su po tome što je u njima bio korišten samo jedan output što se pokazalo problematično jer institucije visokog obrazovanja proizvode mnogo različitih outputa. Novija istraživanja uvažila su visokoobrazovne institucije kao organizacije koje proizvode višestruke outpute od kojih su oni najosnovniji edukacija na dodiplomskoj razini, diplomskoj razini te znanstvena istraživanja. Jedan od prvih autora koji je analizirao ovaj problem je James (1978) te je pokušao razdvojiti troškove preddiplomskog studija, diplomskog studija i istraživanja na sveučilištu. Uočio je da uzimajući u obzir samo jedan output, u njegovom slučaju to su bili studenti preddiplomskog studija, i zanemarujući ostale outpute dolazi do precjenjivanja troška pružanja preddiplomskog obrazovanja.

Jedno od prvih istraživanja efikasnosti modernog tipa gdje se visokoobrazovne institucije uzimaju kao organizacije koje proizvode višestruke outpute je ono autora Cohn, Rhine i Santosa

(1989). Provedeno je na 1887 javnih i privatnih visokoobrazovnih institucija u SAD - u na podacima u rasponu od 1981. – 1982. godine, a njihova troškovna funkcija se sastoji od tri outputa – studenti uključeni u preddiplomsko obrazovanje, studenti uključeni u diplomsko obrazovanje i stipendije za istraživanje i jednog inputa – prosječne plaće na fakultetu. Rezultati su pokazali da i na javnim i na privatnim visokoobrazovnim institucijama postoji izražena ekonomija opsega¹ dok je ekonomija obujma² više izražena u privatnom sektoru. Ovo istraživanje u SAD – u nastavili su De Groot, McMahon i Volkewein (1991) i proširili ga procjenjivanjem troškovne funkcije podskupa od 147 američka sveučilišta s doktorskim studijem. Spomenuta istraživanja pokazala su se izuzetno važna u razumijevanju troškova visokog obrazovanja i ekonomije opsega. Istraživanje koje su proveli Cohn, Rhine i Santos (1989) nastavili su i Laband i Lentz (2003) na način da su ponovo procijenili troškovnu funkciju 1492 privatnih i 1450 javnih visokoobrazovnih institucija u SAD-u za fiskalnu godinu 1995-1996 koristeći troškovnu funkciju s tri outputa. Došli su do zaključka da postoji velika razlika troškovne strukture javnih i privatnih visokoobrazovnih institucija, ali da i jedne i druge mogu smanjiti svoje jedinične troškove tako da se poveća razina outputa u odnosu na postojeće.

Koshal, Koshal i Gupta (2001) su na primjeru 184 bogoslovna fakulteta u SAD – u utvrdili postojanje ekonomije obujma i opsega u visokom obrazovanju. Robst (2001) je koristio pristup procjene granica kako bi analizirao da li je promjena strukture prihoda visokoobrazovnih institucija u SAD - u utjecala na njihovu relativnu efikasnost. U obzir je uzimao institucije s manjim i institucije s većim udjelom izdvajanja od strane države. Također je istražio na koji način su promjene udjela izdvajanja od strane države za svaku pojedinu instituciju utjecala na njezinu relativnu efikasnost u razdoblju od 1991.-1995. Zaključio je da je kod većine institucija udio u prihodima od strane države pao te da su se one visokoobrazovne institucije s nižim padom udjela državnih prihoda pokazale efikasnije nego one kojima je taj udio prihoda značajnije pao.

¹ Ekonomija opsega (engl. *economies of scope*) je koncept smanjivanja jediničnih troškova proizvodnje koji se postiže na način da poduzeće proizvodi određen broj usko povezanih proizvoda. Uštede se postižu na način da se za različite aktivnosti koriste zajednički inputi ili proizvodni, prodajni ili drugi procesi.

² Ekonomija obujma (engl. *economies of scale*) predstavlja troškovne uštede koje se ostvaruje povećanjem obujma proizvodnje. Troškovne uštede se odnose na smanjivanje jediničnih troškova proizvodnje povećanjem njezinog obujma.

Pojedini autori (Verry, Layard, 1975) i (Tierney, 1980) su još u ranijoj fazi vrednovanja efikasnosti došli do zaključka da je potrebno razdvojiti analizu troškovne funkcije različitih odjeljenja unutar sveučilišta jer se odjeli međusobno razlikuju, tako da im se i troškovna funkcija razlikuje. Analiziranje troškovne efikasnosti na razini odjela izvršili su Dundar i Lewis (1995) na 18 javnih američkih sveučilišta kako bi se procijenili njihov stupanj ekonomije opsega i obujma. Izvršili su analizu s više outputa koristeći kvadratnu troškovnu funkciju kako bi odredili efikasnost nastave i istraživanja te najefikasniju kombinaciju outputa ovisno o različitom odjelu. Deset godina kasnije Giménez i Martínez (2006) su u svom radu prezentirali opći model vrednovanja relativne troškovne efikasnosti na bilo kojem tipu organizacije koristeći AOMP. Najveći doprinos njihova modela je taj da kvantificira razliku između promatranih troškova analiziranih jedinica i troškova koje bi ostvarile pretpostavljajući dugoročno minimiziranje troškova. Model ocrta cilj koji je moguće dostići u dugom roku. Empirijsku primjenu modela proveli su na 42 odjela Autonomnog sveučilišta u Barceloni.

U Europi se najveći broj istraživanja relativne efikasnosti visokoobrazovnih institucija provodi u UK. Johnes, Johnes i Thanassoulis (2008) troškovnu funkciju visokoobrazovnih institucija u Engleskoj procijenili su metodama slučajnih efekata i stohastičke granice. Ovaj rad se ističe jer je u njemu izvršena detaljnija razdioba prema subjektu, tipu institucije i lokaciji te je provedeno istraživanje troškovnih implikacija na različite politike proširenja i razlike u efikasnosti koje postoje između različitih institucija. Johnes i Johnes (2009) procijenili su višeproizvodnu troškovnu funkciju visokoobrazovnih institucija u Engleskoj koristeći panel podatke za razdoblje 2000/01-2002/03 na 121 visokoobrazovnoj instituciji. Thanassoulis i dr. (2011) nastavljaju ova istraživanja te naglašavaju važnost vlade UK da razumije strukturu troškova visokog obrazovanja te da na taj način omogući procjenu potencijala za njegovo širenje i s tim povezane troškovne implikacije. U istraživanju su koristili AOMP kako bi procijenili troškovnu strukturu i učinak različitih grupa visokoobrazovnih institucija u Engleskoj od akademske godine 2000/01-2002/2003. Autori uspoređuju jedinične troškove svakog promatranog subjekta dobivene pomoću AOMP-a s onima rezultatima dobivenim parametrijskim procjenama i zaključuju da su oni vrlo slični. Međutim AOMP se pokazala fleksibilnija i dala je bolju procjenu tamo gdje su se institucije specijalizirale u proizvodnji samo određenog outputa. Autori svoje prethodno istraživanje proširuju na način da analiziraju potencijalne uštede i povećanje outputa različitih visokoobrazovnih institucija koristeći različite AOMP modele. Rezultati istraživanja pokazuju znatan prostor povećanja broja studenata bez dodatnih troškova

na način da svaka visokoobrazovna institucija povećava broj studenata tamo gdje ima najveći prostor za napredovanje.

Beasley (1990, 1995) je također proučavao relativnu efikasnost sveučilišta u UK i prvi je uočio problem pri kojem osnovni modeli AOMP - a pretpostavljaju da su svi outputi donosioca odluke nastali kao rezultat jednog proizvodnog procesa. Problem se očituje u tome da se pritom ne može vidjeti kako DO unutar svog poslovanja alocira resurse za proizvodnju različitih outputa. Beasley je pretpostavio da procesi koji stoje iza stvaranja obrazovanja i znanstvenog istraživanja ne moraju biti isti te da DO ne mora biti jednako efikasan pri proizvodnji oba outputa. Zato je predložio da se efikasnost nastavnog i istraživačkog rada odvojeno vrednuju. Mar Molinero (1996) te Tsai i Mar Molinero (2002) nadovezali su se na Beasleyvo istraživanje i dali prijedlog modificiranog modela AOMP – a kojim bi se njegovo rješenje moglo provesti. Ideju odvojenog vrednovanja pojedinih djelatnosti unutar visokog obrazovanja prihvatili su i Korhonen, Tainio i Wallenius. (2001), Wang i Huang (2007) te Cherchye i Vanden Abeele (2005) koji su koristili AOMP kako bi vrednovali efikasnost istraživanja i razvoja (IiR). Casu i Thanassoulis (2006) su izvršili vrednovanje relativne efikasnosti centralne administracije sveučilišta UK, a Coelli (1996) je vrednovanje relativne efikasnosti administrativnog osoblja proveo na 36 Australskih sveučilišta. Horne i Hu (2008) su, koristeći stohastičku analizu granica (SFA), na primjeru 36 australskih sveučilišta kvantificirali relativnu efikasnost nastavnog osoblja australskih sveučilišta.

Postojanje višedimenzionalnosti u poslovanju visokog obrazovanja istaknuli su i Murias, de Miguel i Rodríguez, D. (2008). Oni su mjerili kvalitetu španjolskih sveučilišta korištenjem kompozitnog indikatora. Kvalitetu su prikazali sintetičkim indikatorom koji je dobiven temeljem niza komponenti i jednostavnih indikatora. U analizi je korišten AOMP kako bi se agregirali podaci te su u okviru iste metodologije svakom pojedinom konstruktu ograničene težine temeljem njegove važnosti u agregatnoj ocjeni. Analiza je pokazala signifikantnu razliku između javnih španjolskih sveučilišta.

Može se uočiti kako je najveći broj istraživanja proveden u SAD-u i UK-u. Također je vidljivo da se empirijska analiza relativne efikasnosti visokoobrazovnih institucija uobičajeno provodi ili na način se procjenjuje troškovna funkcija s naglaskom na ekonomiju opsega i obujma ili se analiza relativne efikasnosti provodi korištenjem analize omeđivanja podataka ili funkcija

procjene granica. Većina istraživanja ukazuje da rast ukupnih troškova povećava upis studenata i rast istraživačkih outputa te ukazuju na postojanje ekonomije opsega.

U praksi vrednovanja visokog obrazovanja, valja spomenuti dosadašnja istraživanja usmjerena rangiranju, prije svega, Sveučilišta na svjetskoj razini. Takva istraživanja imaju za svrhu stvaranje kompetitivnosti između različitih sveučilišta te pružanje informacija koje služe kao okosnica za financiranje. Svrha spomenutoga je određivanje kvalitete visokoobrazovnih institucija i njihovog pozicioniranje na globalnoj akademskoj ljestvici te informiranje javnosti o uspješnosti njihova poslovanja. Rangiranje sveučilišta postalo je aktualno posljednjih desetak godina i u tom vremenu se je isprofiliralo nekoliko inicijativa rangiranja svjetskih razmjera. Iako se metodologije korištene pri rangiranju razlikuju jer one prije svega ovise o samoj definiciji kvalitete od koje se polazi, u analizama se poštuje višedimenzionalnost poslovanja institucija. Temeljem poimanja kvalitete, definiraju sve ostale mjere (kriteriji, indikatori) koje služe kao okosnica samog rangiranja.

QS Top Universities (2013) od 2004. provodi rangiranja Sveučilišta na svjetskoj razini i sukladno tome definira i unapređuje indikatore vrednovanja. U istraživanju, QS World University Rankings, indikatori vrednovanja bazirani su djelomično na prikupljenim podacima, a djelomično na podacima dobivenim iz dvije ankete provedene na svjetskoj razini. Jedna se provodi na akademskom osoblju, a druga na poslodavcima. Rangiranje je suženo isključivo na one indikatore koji ne obuhvaćaju direktan angažman samih institucija i mogu biti pouzdano stratificirani po predmetnoj disciplini. U istraživanje nisu uključeni mnogi kriteriji za koje se smatralo da zbog tečaja ili poslovnih ciklusa neće moći biti samostalno vrednovani (npr. prihod od znanstvenog istraživanja). Akademski reputacija predstavlja indikator najveće relativne važnosti s težinom od 40% na svjetskoj razini. Reputacija poslodavca je indeks koji daje informaciju o mogućnosti zapošljavanja i na svjetskoj razini težina mu iznosi 10%. Kao indikator vrednovanja kvalitete nastavnika izabran je omjer studenata u odnosu na nastavnike s težinom od 20% na svjetskoj razini. S obzirom na sve veću globalizaciju i mobilnost unutar akademskih krugova, u obzir je uzet i tzv. internacionalni indikator. Internacionalni indeks fakulteta predstavlja udio stranog osoblja angažiranog na fakultetu (5% težine) dok internacionalni studentski indeks predstavlja udio stranih studenata koji studiraju na fakultetu (5% težine). Istraživačka snaga vrednuje se indikatorom citata po fakultetu, (20%). S područja Hrvatske i zemalja regije prema ovoj klasifikaciji u 2013. godini najviše je rangirano Sveučilište u Ljubljani koje se nalazi između 551. i 600. mjesta. Potom slijedi Sveučilište u Zagrebu između

601 i 650 mjesta te potom Sveučilište u Beogradu iznad 701. mjesta. Ostala sveučilišta s ovih prostora nisu se našla na ljestvici. Niti jedna visokoobrazovna ustanova s područja ekonomije u Hrvatskoj i regiji nije završila na listi od prvih 400 (QS Top Universities, 2013).

Academic ranking of world universities („Shangai ranking“) (2013) smjestilo je Sveučilište u Ljubljani i Sveučilište u Zagrebu u rasponu između 401. i 500. mjesta dok se je Sveučilište u Beogradu pozicioniralo između 301. i 400. mjesta. Niti za jedno od tri spomenuta sveučilišta nisu poznati rezultati za polje ekonomije. Ukupno je rangirano 1.000 sveučilišta, ali je objavljen poredak za prvih 500. Sveučilišta su izabrana temeljem definiranih znanstvenih postignuća, a rangirana su temeljem šest različitih kriterija. Svakom kriteriju su dodijeljeni određeni indikatori koji ga najbolje definiraju, a svakom indikatoru su potom dodijeljene određene težine. Detaljniji pregled kriterija, indikatora i pondera rangiranja sveučilišta prema „Shangai ranking“ prikazan je u sljedećoj tablici.

Tablica 1: Kriteriji, indikatori i ponderi prema „Shangai ranking“

Kriteriji	Indikatori	Težinski faktor
Kvaliteta obrazovanja	Broj završenih studenata (Alumni) koji su dobili Nobelovu nagradu ili drugu relevantnu nagradu u znanstvenom području	10%
Kvaliteta zaposlenih	Broj znanstvenog/nastavnog osoblja koji su dobili Nobelovu nagradu i/ili drugu relevantnu nagradu u znanstvenom području	20%
	Broj visoko citiranih znanstvenika u definiranim područjima znanosti.	20%
Znanstveni rezultati	Broj radova koji su objavljeni u časopisima "Nature" i "Science"	20%
	Broj radova koji su indeksirani u bazama "Science Citation Index - expanded" i "Social Science Citation Index" nakon 2003.	20%
Veličina institucije	Akademski učinak po glavi zaposlenika na instituciji - dobije se tako da se rezultat s težinskim faktorom prethodnih 5 indikatora podjeli s brojem zaposlenih - ekvivalent zaposlenih s punim radnim vremenom. Ukoliko nije moguće dobiti broj zaposlenih, koriste se rezultati gore navedenih pet indikatora.	10%

Izvor: Academic ranking of world universities (2013). Top 500 Universities, dostupno na: <http://www.shanghairanking.com/> (14.07.2014)

Ranking web of universities "Webometrics". (2013) kao glavne ciljeve ističe podržavanje inicijative otvorenog pristupa (eng. *Open Access initiatives*), promociju globalnog pristupa akademskom znanju „proizvedenom“ na svim svjetskim sveučilištima. Pritom koristi odabrane web indikatore, a kompozitini indikator određuje se na sljedeći način:

Tablica 2: Metodologija rangiranja visokoobrazovnih institucija prema „Webometrics“

Područja i težine	Kriteriji	Indikatori
Vidljivost (50%)	Utjecaj	Broj dolaznih linkova od treće strane
Aktivnost (50%)	Prisutnost (1/3)	Broj objavljenih web stranica na glavnoj web domeni
	Otvorenost (1/3)	Broj „rich“ datoteka tj. datoteka tipa pdf, ps, doc i ppt objavljenih na web stranicama u skladu s akademskom tražilicom Google Znalac
	Izvrsnost (1/3)	Akademski radovi objavljeni u međunarodnim časopisima visokog utjecaja - koji spadaju u 10% najcitiranijih radova u svojim znanstvenim područjima.

Izvor: Ranking web of universities „Webometrics“ (2013). dostupno na:

<http://www.webometrics.info/> (14.07.2014)

Webometrics je otišao najdalje po pitanju rangiranja i pružanja informacije za sva sveučilišta i poslovne škole na području Hrvatske, Slovenije, Bosne i Hercegovine, Srbije, Makedonije te Crne gore. Najbolje rangirana sveučilišta i ovdje su Sveučilište u Ljubljani na 342. mjestu, Sveučilište u Beogradu na 480. mjestu i Sveučilište u Zagrebu na 510. mjestu. Rangiranje se vodi izuzev završne ocjene izvrsnosti i ocjenom svakog kriterija zasebno. Ponderiranjem pojedinih indikatora dobiven je kompozitni indikator. Međutim, iako rangira najveći broj visokih učilišta, ne postoji razdioba prema tipu, nego su sve zajedno stavljene na istu listu bez uvažavanja specifičnosti (npr. javne i privatne).

S obzirom na različite pristupe i metodologije rangiranja, postoje i razlike u samim rezultatima koji variraju ovisno o rangiranju. Različite metodologije koriste različite indikatore za iste kriterije i pridružuju im različite težine. Također, tip podataka korišten pri rangiranju se značajno razlikuje, pa razlikujemo one objektivne i subjektivne. Kako bi se prevladala spomenuta ograničenja i pružila kvalitetnija ocjena visokoobrazovnih institucija SERI i CRUS (2013) predložili su da pristupi rangiranja uvažavaju:

- rangiranje pojedine discipline ili odjela umjesto cijele institucije,
- višedimenzionalni koncept kvalitete sveučilišta umjesto jednakog pristupanja svim institucijama bez uvažavanja specifičnosti (različitost institucija misija, ciljeva, jezika i kulture),
- pojedinačno mjerenje i prezentaciju svakog pojedinog indikatora kako bi se uvažile individualne preferencije umjesto cjelokupnog rezultata,

- prezentaciju rezultata rangiranja prema skupinama umjesto prezentacije u obliku skupne liste.

Predloženi pristupi uvaženi su pri izradi modela ove doktorske disertacije.

Valja naglasiti kako prethodno spomenuta rangiranja sveučilišta u području visokog obrazovanja nisu statična već se kontinuirano mijenjaju i prilagođavaju kako bi pružila sveobuhvatnu i kvalitetniju informaciju. Unatoč važnim informacijama, ova istraživanja ne pridaju dovoljnu pozornost problematici visokog obrazovanja na području Hrvatske i regije, pogotovo u polju ekonomije. Također, s obzirom na uključenost velikog broja različitih visokoobrazovnih institucija i njihovu široku geografsku disperziju rangiranja, postavlja se pitanje homogenosti samog uzorka.

Iako je u Hrvatskoj vrednovanje visokoobrazovnih institucija još relativno novo područje, posljednjih godina se može primijetiti znatan porast znanstvenog interesa za ovu temu. Ne postoji općeprihvaćena metodologija vrednovanja kvalitete visokog obrazovanja. Većina, prvenstveno ranijih, istraživanja provedenih na primjeru RH deskriptivno i teorijski su definirala odrednice kvalitete. Oblikovanje praktično - aplikativnih modela uočljivo je tek posljednjih godina. Analiza omeđivanja podataka, iako u svijetu prihvaćena kao jedna od najznačajnijih metoda vrednovanja efikasnosti visokog obrazovanja u RH je slabo korištena. Istraživanja provedena u Hrvatskoj mogu se podijeliti u tri kategorije: vrednovanje sa strane percepcije zadovoljstva studenta, vrednovanje temeljem konstruiranja pokazatelja i modela uspješnosti te vrednovanje relativne efikasnosti korištenjem AOMP.

Sa stajališta percepcije zadovoljstva studenata:

Bečić, Vojinić, Stojčić (2013) su ispitali očekivanja i zadovoljstvo studenata nastavom na preddiplomskom studiju Ekonomije i poslovne ekonomije Sveučilišta u Dubrovniku. Utvrdili su da viša razina zadovoljstva uslugom postoji među uspješnijim studentima s pozitivnim očekivanjima prije upisa na Odjel. Na cjelokupno zadovoljstvo kvalitetom usluge Odjela najveći utjecaj ima stav koji studenti imaju prema kvaliteti održane nastave. Stav studenata o kvaliteti ostalih područja djelovanja također utječe na zadovoljstvo studenata, ali u manjoj mjeri. U istraživanju je korištena ordinalna logistička regresija te Spearmanov koeficijent korelacije. Očekivanja studenata i zadovoljstva studijem također su istražili Mandić, Pavlović (2013) Rezultati ukazuju na važnost primjene osnovnih marketinških načela kod institucija visokog obrazovanja. Istaknuta je i važnost praćenja zadovoljstva studenata i njihovih potreba

za poslovanje i opstanak. Lazibat, Sutić, Baković (2013) su koristili faktorsku analizu kako bi istražili percepcije studenata o sustavima upravljanja kvalitetom na visoko obrazovnim institucijama ekonomskog usmjerenja sa svrhom utvrđivanja stanja kvalitete visokog obrazovanja u hrvatskoj te ostvarivanja mogućih poboljšanja. Polazište u percepciji studenta pronašli su i Leko Šimić, Štimac (2013) koji su istraživali odrednice kvalitete usluge obrazovanja na Ekonomskom fakultetu u Osijeku. Same odrednice kvalitete su definirane od strane studenata, a istraživanje je provedeno na temelju SERVQUAL modela na uzorku od 406 studenata.

Vrednovanje temeljem konstruiranja pokazatelja i modela uspješnosti:

Jedno od ranijih istraživanja vrednovanja u visokom obrazovanju Hrvatske je ono od Jakir – Bajo (2003) gdje se navode razlozi za vrednovanje uspješnosti u javnom sektoru te se prikazuje okvir mjerenja. Analizu uspješnosti visokih učilišta u Republici Hrvatskoj proveli su Ćukušić, Garača i Jadrić (2014) i Budimir (2006) s ciljem utvrđivanja odrednica i pokazatelja uspješnosti visokih učilišta. Temeljem istraživanja iz 2006., Vašiček, Budimir i Letinić (2007) dale su prikaz mjera kvalitete kod pružanja usluga javnog sektora stavljajući naglasak na segment visokog obrazovanja. Također su prikazali sintezu skupova pokazatelja uspješnosti visokog obrazovanja Velike Britanije, Kanade i Australije kao začetnika ideje vrednovanja u visokom obrazovanju. Budimir (2010) je istražila mjerenje uspješnosti poslovanja proračunskih korisnika i rezultati su ukazali da, iako postoji svijest o važnosti mjerenja i prezentiranja tih informacija javnosti, ipak subjekti javnoga sektora, ukoliko i provode spomenuta mjerenja, rade to vrlo rijetko što je, između ostaloga, razlog nerazvijenosti tog sustava. Ćukušić (2011) je odredila najvažnije odrednice koje utječu na uspješnost temeljem čega je razvijen model procesne organizacije visokih učilišta kako bi se optimizirala uspješnost. Napravljen je simulacijski model kojim je dokazan pozitivan utjecaj primjene informatičkih tehnologija na uspješnost obrazovnih procesa visokih učilišta. Okvir razvoja i implementacije pokazatelja uspješnosti definirali su Dražić Lutilsky i Broz Tominac (2013) na primjeru Sveučilištu u Zagrebu (UNIZG) i njegovim sastavnicama na način da se predlažu moguća rješenja za implementaciju pokazatelja uspješnosti UNIZG i oblikuju se koristi te implementacije. Predložena je implementacija BSC modela te su prezentirane mjere i pokazatelji čijom primjenom bi se mogla unaprijediti efikasnost i efektivnost UNIZG i njegovih sastavnica. Prikaz osnovnih čimbenika osiguranja kvalitete u visokom obrazovanju sadrži i istraživanje Ivković (2009) gdje su pored spomenutoga navedena i temeljna načela predviđena Standardima i smjernicama za osiguravanje kvalitete (ESG standardi) u Europskom prostoru visokog

obrazovanja. U ESG standardima također su uporište pronašle Cerović i Arbula (2012) te Cerović, Arbula Blecich i Štambuk (2014) koje su predložile model vrednovanja kvalitete ekonomskih fakulteta na način da su definirana područja vrednovanja kvalitete te je znanstveno potvrđen njihov relativan značaj. Korištena je metoda skupnog indeksa, a mišljenjima eksperata pojedinim područjima kvalitete dodijeljene su pripadajuće težine temeljem čega je postavljen matematički model. Na primjeru Ekonomskog fakulteta u Rijeci prikazani su dotadašnji napori u provedbi evaluacijskih aktivnosti.

Vrednovanje relativne efikasnosti visokog obrazovanja Hrvatske korištenjem AOMP-a:

Vrednovanje relativne efikasnosti potrošnje vlade na visoko obrazovanje u izabranim državama EU s osvrtom na Hrvatsku proveli su Aristovnik i Obadić (2011), Aristovnik (2011a), Arbula (2012). Istraživanja su potvrdila relativno nisku razinu relativne efikasnosti visokog obrazovanja Hrvatske u odnosu na ostale zemlje Europe. Sopek (2012) je pored AOMP-a vrednovanje provela i putem Free Disposable Hull (FDH) metode. Potvrđena je hipoteza o relativnoj neefikasnosti javne potrošnje na obrazovanje te su predstavljeni razlozi te neefikasnosti.

Važno je spomenuti kako svijest o važnosti ove teme raste, kako u društvu, tako i u znanstvenim krugovima. Navedeno potvrđuje rast znanstvenog interesa koji je vidljiv kroz sve veći broj objavljenih znanstvenih radova, posebno posljednjih godina.

Uočljivo je da se relativna efikasnost mjerila za donosioca odluke općenito uzimajući u obzir široki spektar njegovog poslovanja i sumirajući ga u jednu ocjenu. S druge strane često je bio promatran samo jedan dio poslovanja, npr. efikasnost financiranja, troškovna efikasnost, efikasnost nastavnog osoblja, efikasnost istraživanja i razvoja, itd. S obzirom da su visokoobrazovne institucije izuzetno kompleksne, smatra se kako dobivanje samo jedne ocjene ne pruža potpunu sliku relativne efikasnosti svakog područja njihova djelovanja. S druge strane, izoliranje samo jednog područja daje „krmju“ ocjenu jer su zanemarena ostala područja djelovanja. Zbog toga, u ovome radu je izvršena analiza vrednovanja relativne efikasnosti tri različita područja djelovanja visokoobrazovnih institucija i dobivena je ocjena relativne efikasnosti svakog pojedinog područja djelatnosti (nastavna, znanstvena i međunarodna djelatnost). Pored vrednovanja poslovanja svakog pojedinog područja djelovanja

visokoobrazovnih institucija, postavljen je i četvrti model kojim se je izvršilo vrednovanje relativne efikasnosti ukupnog poslovanja. Vrednovanjem su identificirani izvori relativne neefikasnosti za svakog DO za svaki pojedini model te su na temelju rezultata predložene smjernice za potencijalna poboljšanja kojima bi se isti otklonili. Kako bi se došlo do statistički važnih zaključaka korisnih donositeljima obrazovnih politika klaster analizom su visokoobrazovne institucije podijeljene u skupine sukladno rezultatima relativne efikasnosti svakog pojedinog područja te je logističkom regresijom utvrđena vjerojatnosti prelaska u povoljniji klaster temeljem ključnih čimbenika.

1.5. ZNANSTVENE METODE

U ovom znanstvenom istraživanju, formuliranju i prezentaciji rezultata istraživanja doktorske disertacije korištena je kombinacija sljedećih znanstvenih metoda: induktivna i deduktivna metoda, metoda analize i sinteze, povijesna metoda, metoda generalizacije i specijalizacije, metoda apstrakcije i konkretizacije, metoda dokazivanja i opovrgavanja, metoda deskripcije, komparativna metoda, metoda klasifikacije i metoda kompilacije.

Također je u doktorskoj disertaciji korištena i analiza omeđivanja podataka, klaster analiza te univarijantna binarna logistička regresija koje služe kao osnova za izradu modela vrednovanja relativne efikasnosti visokoobrazovnih institucija ekonomskog usmjerenja Republike Hrvatske i država regije s ciljem povećavanja njihove kvalitete.

Analiza omeđivanja podataka je neparametrijska metoda koja se temelji na linearnom programiranju, a koristi se za omeđivanje promatranih podataka kako bi se odredila relativna efikasnost promatranih donosioca odluke. Klaster analiza je multivarijantna statistička metoda koja temeljem određenih varijabli klasificira različite objekte unutar pojedine skupine dok je logistička regresija metoda kojom se na temelju nezavisnih varijabli predviđaju vjerojatnosti različitih mogućih ishoda kriterijske zavisne varijable .

1.6. STRUKTURA RADA

Rezultati istraživanja u doktorskoj disertaciji prezentirani su u osam međusobno povezanih dijelova.

U prvom dijelu, **UVODU**, definiran je problem, predmet i objekt istraživanja, postavljena je temeljna znanstvena hipoteza i pomoćne hipoteze, definirani su svrha i ciljevi istraživanja, dan je prikaz dosadašnjih istraživanja, navedene su najvažnije znanstvene metode korištene u doktorskoj disertaciji te je obrazložena struktura doktorske disertacije.

OPĆE I RAČUNOVODSTVENE ODREDNICE VISOKIH UČILIŠTA JAVNOGA SEKTORA naslov je drugog dijela u kojem se, pored detaljnog iznošenja relevantnih značajki javnoga sektora u segmentu visokog obrazovanja, pojašnjava i osnivanje, organizacija te financiranje visokih učilišta javnoga sektora s ciljem ostvarenja njihovih strateških i proračunskih ciljeva. Također su obrazložena i računovodstvena pravila priznavanja i mjerenja ekonomskih kategorija u visokom obrazovanju te je prikazana primjena koncepta društveno odgovornog računovodstva u segmentu visokog obrazovanja.

Treći dio ima naslov **TEMELJNE ODREDNICE VISOKOG OBRAZOVANJA REPUBLIKE HRVATSKE I DRŽAVA REGIJE S POSEBNIM OSVRTOM NA VISOKOOBRAZOVNE INSTITUCIJE EKONOMSKOG USMJERENJA**. Obrazovanje je jedan od ključnih faktora napretka, rasta i razvoja gospodarstva svake države, pa tako i Republike Hrvatske i država regije. U ovom poglavlju posebna pažnja usmjerena je visokoobrazovnom sustavu spomenutih država s naglaskom na visokoobrazovne institucije ekonomskog usmjerenja koje generiraju relativno najveći broj studenata. U poglavlju se obrazlažu europski i hrvatski kvalifikacijski okvir čija je zadaća osigurati usporednost kvalifikacija na širem europskom prostoru.

Naslov četvrtog dijela je **KONCEPT EFIKASNOSTI I EFEKTIVNOSTI KAO ODREDNICA KVALITETE VISOKOG OBRAZOVANJA**. U ovom dijelu definirani su pojmovi efikasnosti i efektivnosti u području visokog obrazovanja kao ključne stavke definiranja kvalitete visokog obrazovanja. Pored teorijskih postavki temeljnih pojmova, u ovom poglavlju prikazane su provedene reforme visokoobrazovnog sustava Europe s naglaskom na Hrvatsku i regiju koje su uvedene, između ostaloga, i s ciljem poboljšanja kvalitete.

METODOLOŠKI OKVIR ZA MODELIRANJE VREDNOVANJA VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA naslov je petog dijela rada. U ovom dijelu analizirane su metode korištene u doktorskoj disertaciji pri

oblikovanju modela vrednovanja relativne efikasnosti visokoobrazovnih institucija ekonomskog obrazovanja (analiza omeđivanja podataka, klaster analiza i logistička regresija).

Posebna pozornost posvećena je šestom dijelu s naslovom **EMPIRIJSKI MODEL VREDNOVANJA RELATIVNE EFIKASNOSTI VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA REPUBLIKE HRVATSKE I DRŽAVA REGIJE**. U ovom dijelu definirane su pretpostavke i elementi empirijskog modela vrednovanja relativne efikasnosti. Testiran je originalan i alternativan model te su identificirani ključni čimbenici za pripadnost klasteru formiranom temeljem rezultata relativne efikasnosti.

Nakon postavljanja empirijskog modela vrednovanja relativne efikasnosti, u sedmom dijelu postavljen je **KVALITATIVNI MODEL VREDNOVANJA EFEKTIVNOSTI VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA** koji predstavlja teorijsku osnovu definiranja ciljeva svake razine na način da ciljevi niže razine budu u funkciji ciljeva više razine. Također, u okviru ovog modela predložen je proces unutarnjeg vrednovanja ishoda u funkciji ostvarivanja efektivnosti visokoobrazovnih institucija ekonomskog usmjerenja.

ZAKLJUČAK je posljednji dio rada i u njemu su sustavno i koncizno formulirani i prezentirani rezultati znanstvenog istraživanja koji su u ovom radu opširnije izneseni i objašnjeni, a kojima je dokazana postavljena znanstvena hipoteza i pomoćne hipoteze.

Na kraju rada nalazi se pregled korištene literature, popis tablica, grafikona i shema, popis kratica te prilozi.

2. OPĆE I RAČUNOVODSTVENE ODREDNICE VISOKIH UČILIŠTA JAVNOGA SEKTORA

Članstvo Hrvatske u Europskoj uniji donijelo je pred nju velike reforme kojima je, između ostalog podvrgnut i proračunski i obrazovni sustav. Reforme proračuna odnose se uglavnom na promjene u načinu upravljanja proračunskim sredstvima pri čemu se ističe da ona trebaju biti korištena u svrhu ostvarivanja proračunskih ciljeva. Pored obveze i odgovornosti u vidu iznosa ostvarenih troškova u odnosu na one planirane te njihove vrste, javni sektor proračunska sredstva treba trošiti na način da ostvari planirane ciljeve te postigne očekivane rezultate. Ove reforme dovele su i do razvoja pokazatelja uspješnosti javnoga sektora i sustava za njihovo praćenje (Vašiček i dr., 2011)

Temeljna funkcija modernog računovodstva je pružanje informacija korisnicima koji na temelju toga donose odluke (Küpper, 2013). Računovodstveni sustavi proračunskih korisnika većinom zadovoljavaju samo potrebe financijskog računovodstva pružajući informacije u vidu vanjskog izvješćivanja. To izvješćivanje spada u zakonsku obvezu i kroz ta izvješća može se provjeriti na koji način i s kojom namjerom su iskorištena proračunska sredstva potrošena te je li ta potrošnja zakonski opravdana. Sustavi internog izvješćivanja manje su razvijeni, a informacije dobivene tim putem mogu biti izuzetno korisne institucijama pri praćenju i proučavanju troškova te u financijskom upravljanju. Zato treba raditi na tome da se sustavi troškovnog i upravljačkog računovodstva intenzivnije razvijaju i primjenjuju u institucijama javnog sektora te da im koriste kao baza za razvoj financijsko – informacijskih sustava. Kako bi se stvorio funkcionalni računovodstveni sustav primjeren institucijama visokog obrazovanja potrebno je utvrditi svrhu i ciljeve glavnih korisnika samog sustava te sukladno tome rezultate koji se u budućnosti očekuju. S obzirom da su glavni korisnici računovodstvenog sustava visokoobrazovnih institucija država, akademska zajednica i studenti, potrebno je sustav prilagoditi na način da im informacije budu jasne i lako dostupne (Küpper, 2013).

Vrednovanje efikasnosti i efektivnosti u javnom sektoru postalo je jedno od ključnih područja interesa zemalja diljem svijeta. Osnova koja omogućuje to vrednovanje su troškovi koji se stavljaju u međudnos s pruženim uslugama čija se isporučena količina i kvaliteta smatra outputom visokih učilišta.


U ovom poglavlju objašnjene su relevantne značajke javnoga sektora u segmentu visokog obrazovanja, prikazan je proces osnivanja te organizacija visokih učilišta u Republici Hrvatskoj te je prezentiran način financiranja visokih učilišta javnoga sektora u Republici Hrvatskoj i pojedinim zemljama Europe. Također je prikazan koncept proračunskog računovodstva u segmentu visokog obrazovanja te je visoko obrazovanje promatrano kao dio društveno odgovornog računovodstva.

2.1. RELEVANTNE ZNAČAJKE JAVNOGA SEKTORA U SEGMENTU VISOKOG OBRAZOVANJA

Primarna svrha javnoga sektora je zadovoljavanje javnih potreba, odnosno ostvarivanje funkcije medija za provođenje temeljnih funkcija države. Tržište se pokazalo neefikasnim mehanizmom u reguliranju javnih potreba čemu je razlog nemogućnost ostvarenja potrebnih pretpostavki za njegovo funkcioniranje (nemogućnost ostvarivanja konkurentnosti što vodi ka neefikasnoj alokaciji resursa, neka dobra se i kod savršene konkurencije i postojanja zakonske regulative ne mogu osiguravati putem tržišta, javna dobra su namijenjena svima i pojedinci se ne mogu isključiti u pogledu njihove potrošnje i dr.) (Kesner-Škreb, n.d.). Izvršitelji javnih funkcija su u institucionalnom smislu središnja i lokalna država uključujući njihova tijela te druge pravne osobe većinom financirane od strane države. Javne potrebe se financiraju pomoću za to predviđenog proračuna kojim se utvrđuju prihodi i primici te rashodi i izdaci države i jedinica lokalne samouprave, a namiruju se isporukom javnih dobara. Država isporukom javnih dobara zadovoljava javne potrebe te na taj način utječe na rast standarda i sigurnosti svojih građana. Javna dobra obilježava netržišni način isporuke i nekonkurentnost. Ipak, visokoobrazovne institucije su specifične utoliko što se može reći da je konkurentnost njihovih usluga postala značajnije obilježje njihova poslovanja.

Prema Statistici državnih financija (eng. *Government Finance Statistics - GFS*), razvijenoj od strane Međunarodnog monetarnog fonda (MMF-a), javni sektor se sastoji od opće države (središnje države i jedinica regionalne i lokalne samouprave) te javnih ustanova i poduzeća. Jednaku strukturu prati i javni sektor Republike Hrvatske. Temeljna podjela javnog sektora Republike Hrvatske je na opću državu i na javna poduzeća koji se između sebe dijele na potkategorije prikazane na sljedećoj shemi.

Shema 1: Struktura javnog sektora Republike Hrvatske




Izvor: Institut za javne financije (2010): Analiza sustava zaposlenih u hrvatskom javnom sektoru, Istraživački projekt, dostupno na:

<http://www.nsz.hr/datoteke/09-10/Analiza%20sustava%20zaposlenih.pdf> (4.03.2012)

S obzirom da predmet ovog istraživanja nisu javna poduzeća, u nastavku će se pažnja usmjeriti sastavnicama opće države, točnije središnje države pod koju spadaju, između ostalih, i institucije visokog obrazovanja. Institucionalni okvir hrvatskog javnog sektora u pogledu subjekata središnje države i jedinica lokalne i regionalne samouprave prikazan je na sljedećoj shemi.

Shema 2: Institucionalni prikaz hrvatskog javnog sektora - subjekti opće države i jedinice lokalne i regionalne samouprave



Izvor: Vašiček, V. (2015): Proračun i proračunski procesi, Zakonski okvir i obilježja djelatnosti, Planiranje proračuna, Izvršavanje proračuna, Riznica, Dostupno na:

<http://web.efzg.hr/dok/RAC//vvasicek/rno/prora%C4%8Dun%20i%20prora%C4%8Dunski%20proces%202015%20I%20DIO.pdf> (15.07.2015)

Institucije visokog obrazovanja koje su predmet istraživanja ove doktorske disertacije dio su proračunskih korisnika središnje države.

Javni sektor, između ostaloga, obilježava izražena funkcionalna i institucionalna složenost. Problemima koji se vežu uz njegovo djelovanje kao i uz sustav upravljanja njime, uvelike

pridonosi i nemogućnost određivanja ciljeva djelovanja po uzoru na privatni sektor korištenjem isključivo ekonomskih indikatora. Ciljevi su uglavnom usmjereni ostvarivanju zadovoljstva njegovih korisnika što nije jednostavno izmjeriti jer se radi o vrijednostima koje podliježu subjektivnosti. Također, ne postoji ustaljena praksa mjerenja tih indikatora zbog čega je mogućnost propusta i neefikasnog djelovanja veća i izglednija nego u privatnom sektoru. Sukladno tome, u velikom broju zemalja on generira probleme poput nerazmjera između ograničenih i nedostatnih sredstava financiranja i stalno rastućih javnih rashoda, prevelikog broja neefikasne javne administracije, netransparentnosti od samog trošenja javnih sredstava, pa do definiranja obaveza, procedura i odgovornosti nadležnih javnih institucija i same države (Vašiček, 2009). S obzirom da je javni sektor svake države vrlo velik i kompleksan sustav, često su promjene koje se pokušavaju implementirati vrlo spore i nedovoljnog razmjera. Kao problem se još ističe i nedostatak stimuliranja i sankcioniranja radnika koji često zbog toga nisu spremni na promjene. Zbog niza problema javnoga sektora koji se ne rješavaju dovoljno brzo i radikalno, u velikom broju zemalja dolazi do sustava koji je neefikasan i koji kao takav postaje prijetnja gospodarskom rastu i razvoju.

U visokom obrazovanju je, u velikom broju zemalja Europe, uvođenjem Bolonjske deklaracije došlo do korjenitih promjena zbog prilagođavanja visokoobrazovnih sustava njezinim načelima. Visokoobrazovne ustanove, kako bi poboljšale svoje poslovanje te ostvarile dugoročno poslovanje moraju pored svakodnevnih, operativnih ciljeva odrediti dugoročne, strateške ciljeve. Europska komisija (2011) navodi reforme potrebne za održiv rast kojima bi se povećao doprinos sustavu europskog visokog obrazovanja:

- povećati broj diplomiranih studenata na svim razinama visokog obrazovanja;
- poboljšati kvalitetu ljudskog kapitala u visokom obrazovanju;
- stvoriti efikasne i efektivne mehanizme upravljanja i financiranja s ciljem ostvarivanja izvrsnosti;
- jačanje povezanosti između obrazovanja, istraživanja i gospodarstva;
- poboljšanje kvalitete visokog obrazovanja kroz povećanu mobilnost studenata, istraživača i osoblja i međunarodnu suradnju.

Upravo su navedeni prijedlozi bili jedno od ishodišta formiranja empirijskog modela vrednovanja predstavljenog u doktorskoj disertaciji.

2.2. OSNIVANJE I ORGANIZACIJA VISOKIH UČILIŠTA U REPUBLICI HRVATSKOJ

Zakon o ustanovama (1993, čl. 1.) u Republici Hrvatskoj definira ustanovu kao pravnu osobu „koja se osniva za trajno obavljanje djelatnosti odgoja i obrazovanja, znanosti, kulture, informiranja, športa, tjelesne kulture, tehničke kulture, skrbi o djeci, zdravstva, socijalne skrbi, skrbi o invalidima i druge djelatnosti, ako se ne obavlja radi stjecanja dobiti“. Osnivanje ustanova veže se uz djelatnosti važne za opći interes. Iako ustanove nisu primarno usmjerene stjecanju profita i tržišnom djelovanju, sve ih je više koje svoju djelatnost šire i u tom smjeru. Visokoobrazovne ustanove jasan su primjer toga jer dio sredstva ostvaruju financiranjem kroz državni proračun, a dio financiranjem iz vlastitih sredstava.

Prema Zakonu o ustanovama (čl. 5), ustanovu može osnovati fizička i pravna osoba, bila ona domaća ili strana. Kada se radi o osnivanju javnih ustanova, Zakon (čl. 7) ograničava osnivače na Republiku Hrvatsku, jedinice lokalne i regionalne samouprave te, u slučaju da to zakon izrijeком dopušta, zajedničko osnivanje jedinica lokalne i regionalne samouprave i fizičkih i pravnih osoba te dvije jedinice lokalne i regionalne samouprave.

Zakon o znanstvenoj djelatnosti i visokom obrazovanju (2003) uređuje osnivanje visokih učilišta. Pod visokim učilištima smatraju se sveučilište i njegove sastavnice – fakultet i umjetnička akademija te veleučilište i visoka škola. Visoka učilišta mogu biti javna (osniva ih Republika Hrvatska) i privatna (osnivaju se odlukom osnivača sukladno Zakonu o znanstvenoj djelatnosti i visokom obrazovanju (2003) i propisima za osnivanje ustanova). Ukoliko visoko učilište udovoljava uvjetima za početak obavljanja djelatnosti te Nacionalno vijeće za visoko obrazovanje (NVVO) iskaže pozitivno mišljenje, resorni ministar temeljem toga visokom učilištu izdaje dopusnicu i odobrava mu se upis u Upisnik visokih učilišta. Nakon što je upisano u Upisnik visokih učilišta i registar ustanova pri trgovačkom sudu, visoko učilište smije početi s obavljanjem djelatnosti i izvođenjem studijskih programa. Da bi visoko učilište dobilo dopusnicu, ono treba ministru podnijeti zahtjev koji od NVVO traži mišljenje. Ono se mora očitovati o predmetu u roku od tri mjeseca. Nakon isteka tog roka, ukoliko je mišljenje pozitivno, ministar ima mjesec dana za izdavanje dopusnice. Da bi se ista izdala, studijski programi za koje ju je visoko učilište tražilo, trebaju biti usklađeni sa standardima kvalitete koji vrijede u zemljama Europske unije. Nužni uvjeti za izdavanje dopusnice su osiguranje potrebnih prostornih kapaciteta i opreme prilagođenih broju studenta koje visoko učilište

planira upisati, osiguranje potrebnih novčanih sredstava za rad te jamstvo u slučaju privatnih visokih učilišta kojim bi se osigurao nastavak i završetak studija ukoliko visoko učilište prestane s radom ili ukoliko se određeni studijski program prestane održavati. Kao najvažniji preduvjet ipak se ističe postojanje dovoljnog broja osoblja (znanstvenog i stručnog) koji posjeduju potrebne kvalifikacije sukladno standardnom nastavnom opterećenju definiranom kolektivnim ugovorom. Pritom, ukoliko se radi o sveučilištu, barem polovina radnika treba biti zaposlena na puno radno vrijeme, dok u slučaju veleučilišta i visokih škola na puno radno vrijeme treba biti zaposlena barem trećina radnika. Ukoliko sveučilište, veleučilište ili visoka škola ne ispunjavaju potonji uvjet, dopusnica se ipak može izdati, ali pod uvjetom da u periodu od najviše pet godina zaposle potrebne radnike i na godišnjoj razini o tome izvještavaju resornog ministra (Barberić, 2009).

2.2.1. Pojam i ustroj visokih učilišta u Republici Hrvatskoj

U Republici Hrvatskoj se pod pojmom visokih učilišta prvenstveno misli na sveučilišta, veleučilišta i visoke škole. Navedene institucije osnivaju se kao ustanove. Sveučilišta se sastoje od fakulteta, akademija i odjela, a država ih osniva zakonom. Sveučilištima upravlja Senat s Rektorom na čelu te ima autonomiju koja mu je garantirana zakonom. Senat donosi odluke o akademskim pitanjima koja se tiču sveučilišta i njegovih sastavnica. Rektor ima funkciju, a s time i prava i obveze ravnatelja sveučilišta. Sveučilišta i njihove sastavnice osnivaju se kako bi obavljale visokoobrazovnu, znanstvenu, stručnu i umjetničku djelatnost sukladno zakonu i njihovom statutu, a izvode sveučilišne i stručne studije. S druge strane se veleučilišta i visoke škole osnivaju uredbom Vlade, a njima upravljaju vijeća u kojima osnivač (Vlada, MZOS ili drugo vladino tijelo) ima natpolovičnu većinu te time imaju i neposrednu ulogu u samom upravljanju. Osnivaju se kako bi obavljale visokoobrazovnu djelatnost kroz izvođenje stručnih studija te smiju obavljati stručnu, znanstvenu i umjetničku djelatnost sukladno zakonu i vlastitom statutu. (IRO (2010b), Zakon o znanstvenoj djelatnosti i visokom obrazovanju (2003)).

Sveučilišta se Zakonom o znanstvenoj djelatnosti i visokom obrazovanju (2003, čl. 53.) definiraju kao „*obrazovne ustanove koje povezivanjem znanstvenog istraživanja, umjetničkog stvaralaštva, studija i nastave razvijaju znanost, struku i umjetnost, pripremaju studente za obavljanje profesionalnih djelatnosti na temelju znanstvenih spoznaja i metoda kao i umjetničkih vrijednosti, obrazuju znanstveni i umjetnički podmladak, sudjeluju u ostvarivanju društvenih interesa studenata te promiču međunarodnu, posebice europsku suradnju u*

europskom obrazovanju te znanstvenoj i umjetničkoj djelatnosti.“ Zadaća sveučilišta je da objedini svoje sastavnice i osigura im jedinstveno djelovanje temeljem propisane strategije i željenog smjera rasta i razvoja. Odlika sveučilišta je da osniva i provodi sveučilišne studije direktno ili putem svojih sastavnica. Ono ima mogućnost provoditi i stručne studije. U Republici Hrvatskoj trenutno funkcionira sedam javnih sveučilišta (u Zagrebu, Rijeci, Splitu, Osijeku, Dubrovniku, Puli i Zadru). Institucije ekonomskog usmjerenja unutar sveučilišta u Hrvatskoj u obliku fakulteta funkcioniraju u Zagrebu, Rijeci, Splitu, Osijeku i Puli, dok u Dubrovniku, i Zadru one funkcioniraju na razini odjela. Pritom valja napomenuti kako je Fakultet ekonomije i turizma "Dr. Mijo Mirković" iz Pule od 06. veljače 2013. prestao funkcionirati na razini odjela Sveučilišta u Puli, a počeo funkcionirati kao fakultet. Tijela sveučilišta su rektor (čelna osoba sveučilišta koja se bira na razdoblje od četiri godine), senat (izborno stručno tijelo birano na način da u njemu postoji uravnotežen odnos između sastavnica sveučilišta, odnosno različitih područja znanosti i umjetnosti), sveučilišno vijeće (tijelo koje se sastoji od čelnika sveučilišta i njegovih sastavnica, a donosi odluke koje se tiču akademske zajednice) i sveučilišni savjet (sveučilišno tijelo koje vodi brige o tome da sveučilište ostvaruje svoju temeljnu djelatnost, da se razvija u pravom smjeru vezanom za društvo unutar kojega djeluje te raspravlja o odlukama donesenim od strane senata i potvrđuje ih). (IRO (2010a), Zakon o znanstvenoj djelatnosti i visokom obrazovanju (2003)).

2.2.2. Oblici organizacije visokih učilišta u Republici Hrvatskoj

Visoka učilišta su sve ustanove koje se bave poslovima visokog obrazovanja te su ovlaštena za ustroj i izvedbu studija, znanstvenog, visokostručnog ili umjetničkog rada (Zakon o visokim učilištima, 1993, čl.2). AZVO (2013a) navodi da trenutno u RH posluju 122 visoka učilišta sa statusom ustanove: *“7 javnih sveučilišta, 3 privatna sveučilišta, 67 fakulteta i akademija, 2 privatna veleučilišta, 13 javnih veleučilišta, 27 privatne visoke škole i 3 javne visoke škole.”*

Zakon o visokim učilištima (1993, čl.2) definira sljedeće organizacijske oblike visokih učilišta u Republici Hrvatskoj:

1. Sveučilište – ima funkciju ustrojavanja i izvođenja sveučilišnih studija, znanstvenog i visokostručnog rada te potiče razvoj vrhunskog umjetničkog i tehnološkog stvaralaštva,
2. Veleučilište – ima funkciju ustrojavanja i izvođenja stručnih studija te razvija visokostručni i umjetnički rad, iznimno i znanstveni rad,

3. Fakultet - djeluje kao sastavnica sveučilišta te sukladno tome ima funkciju ustrojavanja i izvođenja sveučilišnih studija, znanstvenog i visokostručnog rada u jednom ili više područja obrazovanja i znanosti,
4. Umjetnička akademija - djeluje kao sastavnica sveučilišta te sukladno tome ima funkciju ustrojavanja i izvođenja sveučilišnih studija, znanstvenog i umjetničkog rada u jednom ili više područja obrazovanja, znanosti i umjetnosti,
5. Visoka škola (stručna ili umjetnička) – može djelovati kao sastavnica veleučilišta ili samostalno, izvan veleučilišta te ima funkciju ustrojavanja i izvođenja stručnih studija i visokostručnog rada u jednom ili više područja obrazovanja,
6. Odjel – djeluje unutar sveučilišta kao njegova ustrojbeno jedinica koja izvodi sveučilišne studije te ima funkciju ustrojavanja i izvođenja znanstvenog, nastavnog i visokostručnog rada u jednom znanstvenom polju. U pravilu su u odjelu svi nastavnici i suradnici sveučilišta koji djeluju unutar znanstvenog polja odjela,
7. Veleučilišni odjel – djeluje unutar veleučilišta kao njegova ustrojbeno jedinica koja izvodi stručne studije te ima funkciju ustrojavanja i izvođenja nastavnog i visokostručnog rada u jednom području.

2.3. FINANCIRANJE VISOKIH UČILIŠTA JAVNOGA SEKTORA

Visoka učilišta su institucije koje se, izuzev djelatnosti visokog obrazovanja, bave i znanstvenom djelatnošću. Ove djelatnosti su, kao što Zakon o znanstvenoj djelatnosti i visokom obrazovanju (2003) navodi, od posebnog interesa za državu te su „*dio međunarodnog znanstvenog, umjetničkog i obrazovnog prostora*„ gdje se posebno naglašava njihova važnost unutar Europe. Zakon (čl. 107) definira i financiranje ovih djelatnosti, na način da se one financiraju iz:

1. „*sredstava osnivača*,
2. *državnog proračuna Republike Hrvatske*,
3. *proračuna županija, gradova i općina*,
4. *Nacionalne zaklade za znanost, visoko školstvo i tehnološki razvoj Republike Hrvatske*,

5. *vlastitih prihoda ostvarenih na tržištu od školarina, istraživačkih, umjetničkih i stručnih projekata, elaborata, ekspertiza, nakladničke i druge djelatnosti,*
6. *sveučilišnih i drugih zaklada, ostvarene dobiti trgovačkih društava i drugih pravnih osoba iz članka 66. ovog Zakona,*
7. *izravnih ulaganja pojedinaca, trgovačkih društava i drugih pravnih osoba,*
8. *donacija te*
9. *ostalih izvora.“*

Pritom se u Zakonu (čl. 107.) navodi i da izvori financiranja ne smiju utjecati na neovisnost i dostojanstvo institucije ta da se vlastiti prihodi smiju ostvarivati isključivo iz djelatnosti koje ne utječu negativno na postizanje temeljnih funkcija institucije.

Najveći dio sredstava visoka učilišta dobiju iz državnog proračuna. Temeljni kriteriji raspodjele navedenih sredstava su kapaciteti visokog učilišta, cijena pojedinih studija te ocjena njihove kvalitete dobivena temeljem vrednovanja Agencije za znanost i visoko obrazovanje koje se vrši jednom u pet godina. Savjet za financiranje znanstvene djelatnosti i visokog obrazovanja uzima u razmatranje prijedlog proračuna kojim je definirano, između ostaloga, i financiranje visokih učilišta, te ga dostavlja Nacionalnom vijeću za znanost, visoko obrazovanje i tehnološki razvoj sa svojim istaknutim mišljenjem o istom. Temeljem prijedloga i mišljenja dobivenih od strane Savjeta, Nacionalno vijeće za znanost, visoko obrazovanje i tehnološki razvoj donosi konačan prijedlog raspodjele proračunskih sredstava koji dostavljaju resornom ministru (Zakon o znanstvenoj djelatnosti i visokom obrazovanju, 2003).

Sveučilišta za razliku od veleučilišta i visokih škola imaju autonomiju, između ostaloga, i po pitanju financiranja. To znači kako imaju mogućnost samostalnog upravljanja sredstvima državnog proračuna koja im se doznače na račun. U Hrvatskoj je prisutan tzv. sustav povijesne alokacije sredstava prema kojem se sredstva institucijama visokog obrazovanja uglavnom dodjeljuju temeljem odobrenog iznosa iz prethodne proračunske godine korigiranog za promjenu BDP-a. Tim sredstvima se uglavnom financiraju plaće zaposlenika i materijalni troškovi. OECD smatra kako je ovakav način raspodjele sredstava previše rigidan i krut jer ne omogućava planiranje u srednjem i dugom roku i značajno otežava mogućnost provedbe strateških ciljeva. Tradicionalno financiranje institucija visokog obrazovanja od strane državnog proračuna se u Hrvatskoj odvijalo na način da se na razini sastavnice sveučilišta dogovaralo s MZOS-om. Takvim modelom same institucije nisu mogle samostalno premješati

dodijeljena sredstva između stavki. Od 2003. godine, donošenjem Zakona o znanstvenoj djelatnosti visokom obrazovanju (2003), definirano je korištenje drugog oblika financiranja koji podrazumijeva da MZOS sredstva iz proračuna uplaćuje cjeloviti iznos na račun sveučilišta koje onda samostalno raspoređuje ta sredstva između svojih sastavnica (tzv. eng. lump sum model – model cjelovitog proračuna, odnosno programski ugovori s ministarstvom). Iako je 2006. godina bila zakonski rok za primjenu ovog vida financiranja, on još nije u potpunosti implementiran. Glavni problem je taj da fakulteti i ostale sastavnice sveučilišta imaju pravnu osobnost što dovodi do nemogućnosti krovnog upravljanja financiranjem od strane sveučilišta te je u praksi još uvijek izražen tradicionalan model financiranja (IRO (2010a), MZOS (2013a)).

Pitanje financiranja visokog obrazovanja izuzetno je bitno jer je utvrđena visoka pozitivna povezanost između stupnja obrazovanja i industrijskog razvoja. Pozitivan utjecaj razine obrazovanja izražen je i kroz dodatne pozitivne učinke kao što su očuvanje i održavanje slobode, suradnje, mira, povjerenja i ostalih institucionalnih dobara koje imaju pozitivan utjecaj na socio-ekonomski razvoj zemlje (Guisan, Aguayo, Exposito, 2001).

Visoka učilišta ne financiraju se isključivo putem proračunskih sredstava nego dio sredstava prikupljaju drugim načinima definiranim Zakonom o znanstvenoj djelatnosti i visokom obrazovanju (2003). Upravo udio tih prihoda raste u ukupnim sredstvima kojima visoka učilišta raspolažu. Javna potrošnja na obrazovanje i visoko obrazovanje obično se ističe kao bitna stavka postizanja kvalitete. Ipak, neka istraživanja (Jafarov, Gunnarsson, 2008) su dokazala kako postoji neefikasnost u javnoj potrošnji. Efikasnost hrvatske javne potrošnje u sektoru visokog obrazovanja vrlo je slabo istraživana, ali pojedina istraživanja (Aristovnik i Obadić (2011), Arbula, (2012)) dokazala su kako Hrvatska relativno neefikasno troši raspoloživa sredstva po studentu te je u analizama bila pri kraju poretka između promatranih zemalja.

Financiranje visokih učilišta u svijetu i Hrvatskoj postalo je jedna od ključnih tema. Javnim visokim učilištima svakim danom konkurencija je sve veća, što od strane drugih javnih i privatnih visokoobrazovnih institucija u državi, što od brojnih visokoobrazovnih institucija izvan matične države. Bolonjskim procesom otvorile su se granice Europe te bi sukladno Bolonjskoj deklaraciji diplome ostvarene u Hrvatskoj trebale biti usporedive i prihvaćene na području Unije. Time se pred visokoobrazovne institucije stavlja sve veća odgovornost kako bi pripremile studente i od njih stvorile kvalitetne stručnjake koji bi bili konkurentni na međunarodnom tržištu rada.

2.3.1. Financiranje visokih učilišta javnoga sektora u zemljama Europe

Europska unija, kako bi ostvarila željenu razinu kvalitete visokog obrazovanja, potiče visokoobrazovne sustave zemalja članica prema jedinstvenom sustavu visokog obrazovanja. U interesu je svake države članice EU, kao i onih koje joj se žele priključiti da primjenjuju postavljene standarde s ciljem ujedinjenja europskog visokog obrazovanja i poticanja suradnje između različitih sveučilišta i fakulteta. Financiranje visokog obrazovanja bitno je pitanje svake države. Financiranje javnih visokih učilišta u Europi vrši se na nekoliko načina. Veći dio poslovanja visokih učilišta financira se putem sredstava iz proračuna matične zemlje. Pored javnih sredstava, financiranje se vrši i putem privatnih sredstava (npr. školarine i administrativne pristojbe) te iz trećih izvora kroz financiranje usluga, projekata i istraživanja. Potonji izvori financiranja mogu biti javni ili privatni (Dragija, Letica, 2014).

Obzirom da svaka država ima važnu ulogu u financiranju vlastitog sustava visokog obrazovanja, udio BDP –a koji izdvaja za njega predstavlja jedan od ključnih pokazatelja. Postoji mišljenje kako su države koje više izdvajaju za obrazovanje više razvijene.

Kroz sve tri promatrane godine Danska je ulagala najveći udio BDP – a u visoko obrazovanje te je on znatno viši od prosjeka EU. Hrvatska je u promatranom razdoblju bila među pet zemalja s najnižim izdvajanjima. Udio ulaganja Hrvatske u ukupno obrazovanje je u promatranom razdoblju bilo u laganom, ali konstantnom padu. U slučaju visokog obrazovanja, udio BDP-a koji se izdvaja u njega je u 2010. pao u odnosu na prethodnu godinu, dok je u 2011. zabilježen porast u odnosu na prethodne dvije godine. Iako su posljednji dostupni podaci oni za 2011. godinu, s obzirom da se udio izdvajanja za obrazovanje i visoko obrazovanje kod prosjeka EU, kao i kod njezinih članica, relativno malo mijenjao u tri posljednje dostupne godine, a temeljem parcijalnih podataka dostupnih iz drugih izvora, pretpostavlja se da niti u narednim godinama nije došlo do značajnijih promjena. Spomenuto potvrđuju i podaci prikazani u tablici 3.

**Tablica 3: Ukupni javni izdaci na obrazovanje i visoko obrazovanje kao udio u BDP-u
(2009 – 2011)**

	2009		2010		2011	
	BDP/VO	BDP/O	BDP/VO	BDP/O	BDP/VO	BDP/O
EU21 prosjek	1,4	5,9	1,5	6	1,5	5,8
EU28 prosjek	1,21	5,38	1,25	5,41	1,27	5,25
Austrija	1,4	5,9	1,5	5,8	1,5	5,7
Belgija	1,5	6,7	1,4	6,6	1,4	6,6
Češka	1,3	4,8	1,2	4,7	1,4	5,0
Danska	1,9	7,9	1,6	8	1,9	7,9
Estonija	1,6	6,3	1,6	6	1,7	5,5
Finska	1,9	6,4	1,9	6,5	1,9	6,5
Francuska	1,5	6,3	1,5	6,3	1,5	6,1
Island	1,3	8,1	1,2	7,7	1,2	7,7
Irska	1,6	6,3	1,6	6,4	1,5	6,2
Italija	1	4,9	1	4,7	1,0	4,6
Nizozemska	1,7	6,2	1,7	6,3	1,8	6,2
Poljska	1,5	5,8	1,5	5,8	1,3	5,5
Portugal	1,4	5,9	1,5	5,8	1,4	5,5
Slovačka	0,9	4,7	0,9	4,6	1,0	4,4
Slovenija	1,3	6	1,3	5,9	1,3	5,9
Španjolska	1,3	5,6	1,3	5,6	1,3	5,5
Švedska	1,8	6,7	1,8	6,5	1,7	6,3
UK	1,3	6	1,4	6,5	1,2	6,4
Hrvatska	0,83	4,42	0,79	4,31	0,93	4,21

BDP/O - javna potrošnja na obrazovanje kao udio BDP – a

BDP/VO - javna potrošnja na visoko obrazovanje kao udio BDP – a

Izvor: Organisation for Economic Cooperation and Development (OECD) (2012 – 2014). Education at a Glance Report 2012 -2014, Paris, Eurostat (2014). Expenditure on education as % of GDP or public expenditure http://appsso.eurostat.ec.europa.eu/nui/submitViewTableAction.do?sessionId=KRuRjC1XoDV5KZazM_CTawARqJQtvdzxUQBTKBGpYyGKMijqROJt!1846957472

Iako se u Europi visoko obrazovanje tradicionalno većinom financira iz javnih sredstava, ipak postoje značajne razlike između država. Ujedinjeno kraljevstvo ističe se s najnižim udjelom javnog financiranja s udjelom od ispod 30%. S druge strane se Danska, koja najviši udio BDP-a ulaže u obrazovanje i visoko obrazovanje, gotovo u potpunosti financira javnim izvorima.

Kod pojedinih zemalja udio javnog financiranja u odnosu na privatno opada u promatranom razdoblju (npr. Francuska, Španjolska), dok je kod pojedinih zemalja zabilježen porast (npr. Slovačka, Belgija). Unatoč tome je li udio javnih u odnosu na privatne izvore financiranja pao ili porastao, u promatranom razdoblju odstupanja su vrlo mala, pa se može pretpostaviti da niti u narednim razdobljima za koja trenutno podaci nisu dostupni nije došlo do značajnijih odstupanja.

U nastavku je prikazana struktura financiranja visokog obrazovanja odabranih članica EU sa stajališta javnih i privatnih izvora.

Tablica 4: Udio javnog i privatnog financiranja visokog obrazovanja u promatranim državama EU od 2009 – 2011

	2009		2010		2011	
	UJF	UPF	UJF	UPF	UJF	UPF
EU21 prosjek	78,6	21,4	77,3	22,7	78,6	21,4
Austrija	87,7	12,3	87,8	12,2	86,9	13,1
Belgija	89,7	10,3	89,8	10,2	90,1	9,9
Češka	79,9	20,1	78,8	21,2	81,1	18,9
Danska	95,4	4,6	95,0	5	94,5	5,5
Estonija	80,2	19,8	75,4	24,6	80,4	19,6
Finska	95,8	4,2	95,9	4,1	95,9	4,1
Francuska	83,1	16,9	81,9	18,1	80,8	19,2
Island	92	8	91,2	8,8	90,6	9,4
Irska	83,8	16,2	81,2	18,8	80,5	19,5
Italija	68,6	31,4	67,6	32,4	66,5	33,5
Nizozemska	72	28	71,8	28,2	70,8	29,2
Poljska	69,7	30,3	70,6	29,4	75,5	24,5
Portugal	70,9	29,1	69,0	31	68,6	31,4
Slovačka	70	30	70,2	29,8	76,9	23,1
Slovenija	85,1	14,9	84,7	15,3	85,2	14,8
Španjolska	79,1	20,9	78,2	21,8	77,5	22,5
Švedska	89,8	10,2	90,6	9,4	89,5	10,5
UK	29,6	70,4	25,2	74,8	30,2	69,8

UJF – Udio javnog financiranja

UPF – Udio privatnog financiranja

Izvor: Organisation for Economic Cooperation and Development (OECD), (2012 – 2014). Education at a Glance Report 2012 -2014, Paris

S obzirom da su izdvajanja po studentu važan pokazatelj ulaganja u visokom obrazovanju, u tablici 5 prikazan je njihov iznos u izdvojenim državama Europske unije.

Tablica 5: Godišnja izdvajanja na visoko obrazovanje po studentu, bez sredstava za istraživanje i razvoj 2004. i 2011.

	2004*	2011*	Promjena u visini ulaganja po studentu
Austrija	9.595	10.487	109
Češka	5.711	6.320	111
Irska	4.775	11.938	250
UK	8.792	10.570	120
Slovenija	6.866	8.279	121
Italija	4.812	6.482	135
Njemačka	7.724	10.164	132

* Vrijednosti su izražene u ekvivalentu USD konvertiranih putem pariteta kupovne moći (PPP) za BDP u odabranim članicama EU

Izvor: Obrada autorice prema: Organisation for Economic Cooperation and Development (OECD) (2012 – 2014). Education at a Glance Report 2012 -2014, Paris

Izdvajanja po studentu značajno se razlikuju između izabranih zemalja, ali je kod svih zabilježen njihov rast u razdoblju od 2004. – 2011. Najveću promjenu zabilježila je Irska gdje su 2004. ulaganja po studentu iznosila 4.775 USD, dok su 2011. iznosila 2,5 puta više. Time je postala predvodnica u godišnjim izdvajanjima po studentu između izabranih zemalja.

U Europi se tradicionalno visoko obrazovanje manjim dijelom financira iz privatnih izvora, a većim dijelom iz javnih izvora. Iako se sve više financiranje vlastitim izvorima ističe kao prioritet, vidljivo je kako to u praksi još nije u potpunosti zaživjelo. Neovisno o tipu financiranja, evidentno je kako su financijska sredstva prijeko potrebna institucijama visokog obrazovanja kako bi čim kvalitetnije mogle obavljati svoje temeljne funkcije, kako obrazovanja stanovništva, tako i znanstvenog rada.

2.3.2. Financiranje visokih učilišta javnoga sektora u Republici Hrvatskoj

Jedan od temeljnih ciljeva Hrvatske vanjske politike bio je ulazak u punopravno članstvo Europske unije. Sukladno tome, između ostalog, Hrvatska je trebala uskladiti i svoj obrazovni sustav s onim u Uniji. Potpisivanjem Bolonjske deklaracije napravljen je ključan korak prema osnivanju europskog prostora visokog obrazovanja. S obzirom da postoji snažan utjecaj politika financiranja na ostvarivanje ciljeva visokih učilišta, ova tema je izuzetno bitna.

Model financiranja visokih učilišta u Hrvatskoj veže se uz financiranje iz proračuna s obzirom da većinu prihoda ostvaruju putem proračunskih izdvajanja. Manji dio sredstava osigurava se privatnim izvorima te putem treće strane. Suprotno politici financiranja javnih visokih učilišta, privatna se uglavnom financiraju vlastitim sredstvima (Dragija, Letica, 2014). Iznosi koji se dodjeljuju visokim učilištima iz proračuna definiraju se povijesnom troškovnom metodom na način da se iznosi dodijeljeni prethodne godine korigiraju za promjene u BDP-u (Hunjak, 2008). Zakon o znanstvenoj djelatnosti i visokom obrazovanju (2003) definirao je model cjelovitog proračuna kojim MZOS sredstva dodjeljuje sveučilištima koja ih potom samostalno raspoređuju svojim sastavnicama. Ovaj način financiranja predstavlja direktnu vezu na relaciji sveučilišta – državna riznica. Iako je postupak prelaska na ovakav način financiranja u tijeku, on još uvijek nije u potpunosti proveden u praksi (Dragija, Letica, 2014).

Na sljedećoj tablici prikazan je apsolutni iznos proračunskih ulaganja u visoko obrazovanje, znanost te tehnologiju i ICT (informacijsko komunikacijske tehnologije) u Republici Hrvatskoj. U razdoblju od 2003. – 2011. godine jasno je vidljiva dinamika proračunskih izdvajanja za znanost i visoko obrazovanje. Do 2008. godine porast je bio konstantan u svim promatranim segmentima dok je nakon 2008. godine zabilježen pad ulaganja. Taj pad je najslabiji u području visokog obrazovanja dok je u znanosti, tehnologiji i ICT – u on značajniji. Razlog smanjenja proračunskih ulaganja može se tražiti u ekonomskoj krizi koja je 2008. godine zahvatila i Republiku Hrvatsku te koja je dovela do smanjenja ulaganja u javnom sektoru, pa tako i u visokom obrazovanju, znanosti i tehnologiji.

Tablica 6: Proračunska ulaganja Ministarstva znanosti, obrazovanja i sporta Republike Hrvatske u visoko obrazovanje, znanost i tehnologiju u milijunima kuna

	Visoko obrazovanje	Znanost (instituti, projekti, novaci i infrastruktura)	Tehnologija i ICT	UKUPNO
2003.	1.688	751	222	2.661
2004.	1.863	714	252	2.829
2005.	2.043	752	297	3.092
2006.	2.164	813	317	3.294
2007.	2.348	840	269	3.457
2008.	2.644	926	317	3.887
2009.	2.481	922	310	3.713
2010.	2.508	912	302	3.722
2011.	2.736	904	217	3.857

Izvor: Ministarstvo znanosti, obrazovanja i sporta (MZOS) (n.d): Znanost u Hrvatskoj pred ulazak u EU, dostupno na: public.mzos.hr/lgs.axd?t=16&id=19195 (12.04.2013)

Unatoč padu proračunskih ulaganja u pojedinim područjima, zahvaljujući laganom porastu izdvajanja za visoko obrazovanje u 2011. godini, ukupna izdvajanja za znanost i visoko obrazovanje te godine su zabilježila porast u odnosu na prethodno razdoblje. S obzirom na lagana odstupanja u posljednje četiri godine, pretpostavlja se kako i u narednim godinama nije došlo do značajnijih promjena.

Visokim učilištima namjenjuje se dio sredstava iz proračuna sukladno programu njihova rada te ustroju radnih mjesta. (Bajo, 2003). Iako je udio financiranja vlastitim izvorima u porastu, ipak je javno financiranje još uvijek najvažniji izvor sredstava javnih visokih učilišta. Državnim budžetom osiguravaju se sredstva visokom obrazovanju koja se raspodjeljuju preko MZOS-a. Iznos sredstava ovisan je o broju studenata kao i o procijenjenim troškovima po studentu. Ministarstvo vrši raspored sredstava za djelatnost, posebno za nastavne programe. Proračunskim sredstvima se financiraju: plaće i naknade zaposlenih, materijalni troškovi, najnužnija razina znanstvenog, umjetničkog i stručnog rada na visokoobrazovnim institucijama, rad službe čijom se djelatnošću omogućavaju nužni standard sustava za visoko obrazovanje, stipendije i zajmove studentima, financijsku pomoć za školarine, razvoj i investiranje (Kovačević, Sisek, 2007).

Izravnim i neizravnim financiranjem institucija visokog obrazovanja vrši se alokacija javnih izdataka za visoko obrazovanje. Kod javnog financiranja posebno je istaknuta raznovrsnost modela financiranja studija. Javno financiranje se usmjerava putem neizravnih državnih potpora, a kao temeljnu funkciju ima porast raspoloživog dohotka studenta (Vehovec, 2009). U neizravno financiranje ubrajaju se svi oblici financijske potpore dani studentima u obliku školarina, nepovratnih kredita, zajmova iz javnih izvora i slično.

Kod odobravanja visine sredstava proračuna, prvo se obavlja prosudba stvarnih troškova za izvedbu programa studija visokih učilišta od strane Vijeća za novčanu potporu te stručnog povjerenstva. Ovisno o prosudbi, MZOS predlaže da se sredstva doznače visokim učilištima sukladno stvarnim troškovima s time da se doznake umanjuju za 20% prihoda ostvarenih u prethodnoj akademskoj godini. Sredstvima uštedenim tim putem financiraju se ona visoka učilišta koja nisu u mogućnosti da ostvare vlastite prihode (Pravilnik o osnovama financiranja visoke naobrazbe na javnim visokim učilištima, 1996). Iako javno financiranje dominira u visokom obrazovanju Hrvatske, u odnosu na većinu država Europske unije ono je vrlo skromno i iznosi manje od 1% BDP-a.

Tablica 7: Udjel visokog obrazovanja i liR-a u BDP-u Hrvatskoj od 2007. - 2011. godine

	2007.	2008.	2009.	2010.	2011.
Javna potrošnja na visoko obrazovanje (%BDP-a)	0.79	0.94	0.83	0.79	0.93

Izvor: UNESCO (n.d.). Government expenditure on tertiary education as % of GDP (%), dostupno na: <http://data.uis.unesco.org/?queryid=181#> (14.07.2015)

Visoko se obrazovanje u Hrvatskoj, kao kod većine zemalja Europske unije, tradicionalno većim dijelom financira javnim sredstvima. Unatoč tome, financiranje privatnim sredstvima dobiva sve veći značaj (Bajo, 2003). Zanimljivo je spomenuti da se fakulteti ekonomskog usmjerenja u Republici Hrvatskoj financiraju često i s više od 50% vlastitih prihoda, dok je na razini sveučilišta situacija poprilično drugačija. Postoje velike razlike po pitanju udjela pojedinih vrsta prihoda u ukupnim приходima i rashoda u ukupnim rashodima. Spomenuto je prikazano sljedećom tablicom.

Tablica 8: Udio prihoda i rashoda po vrsti u ukupnim приходima i rashodima javnih sveučilišta u Hrvatskoj

	UNIZG		UNIRI		UNIOS		UNIST		UNIZD		UNIDU		UNIPU	
	2011	2012	2011	2012	2011	2012	2011	2012	2011	2012	2011	2012	2011	2012
Pomoći iz inozemstva (darovnice) i od subjekata unutar općeg proračuna	55,20%	54,48%	4,59%	4,69%	1,57%	3,14%	3,23%	4,70%	1,49%	1,11%	1,31%	2,16%	4,12%	3,98%
Prihodi od imovine	0,23%	0,05%	0,44%	0,76%	0,14%	0,20%	0,18%	0,69%	0,20%	0,24%	0,51%	0,92%	0,15%	0,24%
Prihodi od upravnih i administrativnih pristojbi, pristojbi po posebnim propisima i naknada	0,90%	0,68%	3,00%	3,65%	6,49%	6,18%	0,03%	0,01%	0,00%	0,02%	10,45%	7,97%	10,29%	10,07%
Prihodi od prodaje proizvoda i robe te pruženih usluga i prihodi od donacija	8,97%	5,11%	9,62%	8,20%	1,44%	3,39%	8,14%	18,20%	25,77%	28,23%	9,89%	9,18%	7,40%	5,52%
Prihodi iz proračuna	34,68%	39,63%	82,32%	82,69%	90,11%	86,99%	88,30%	76,36%	72,48%	70,14%	76,67%	79,42%	78,02%	80,08%
Kazne, upravne mjere i ostali prihodi	0,02%	0,05%	0,04%	0,00%	0,23%	0,04%	0,11%	0,04%	0,04%	0,21%	1,15%	0,33%	0,00%	0,09%
Prihodi od prodaje nefinancijske imovine	0,00%	0,00%	0,00%	0,00%	0,00%	0,05%	0,00%	0,00%	0,01%	0,05%	0,00%	0,00%	0,01%	0,01%
Rashodi za zaposlene	18,80%	15,06%	52,62%	48,86%	29,51%	44,61%	18,78%	23,17%	60,55%	60,65%	39,14%	44,94%	75,25%	76,73%
Materijalni rashodi	73,56%	71,77%	27,81%	19,79%	15,99%	24,17%	17,05%	22,36%	29,29%	29,02%	14,48%	18,41%	21,13%	19,39%
Financijski rashodi	0,08%	0,11%	0,07%	0,06%	0,06%	0,10%	0,08%	0,04%	0,08%	0,07%	3,18%	6,77%	0,05%	0,06%
Pomoći dane u inozemstvo i unutar općeg proračuna	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,09%	0,00%
Naknade građanima i kućanstvima na temelju osiguranja i druge naknade	5,78%	6,12%	2,62%	2,56%	0,93%	2,50%	0,33%	0,40%	1,44%	1,59%	0,35%	0,42%	1,15%	0,76%
Ostali rashodi	0,11%	0,03%	2,35%	1,85%	0,03%	0,11%	0,00%	0,00%	5,34%	5,34%	0,73%	0,23%	0,04%	0,06%
Rashodi za nabavu nefinancijske imovine	1,67%	6,91%	14,53%	26,88%	53,47%	28,51%	63,75%	54,03%	3,31%	3,32%	42,12%	29,23%	2,29%	3,00%

Izvor: Izradila autorica prema: Ministarstvo financija Republike Hrvatske (MFIN) (2013) – Temeljni financijski izvještaji javnih visokih učilišta u periodu od 2011. – 2012.

Sva sveučilišta se u većini financiraju iz proračuna. Stavka prihoda iz proračuna pokazuje koliko država izdvaja novca za financiranje redovnog poslovanja sveučilišta. Pomoći iz inozemstva (darovnice) i od subjekata unutar općeg proračuna koje u primjeru Sveučilišta u Zagrebu u ukupnim приходima učestvuju s otprilike 55% također su gotovo u potpunosti pristigle od strane države tako da se mogu promatrati kao prihodi iz proračuna.

Kod rashoda također postoje razlike između sveučilišta s time da su rashodi za zaposlene i materijalni rashodi kod svih subjekata najviše stavke unutar ukupnih rashoda.

Kako bi se prikazala dinamika kretanja pojedinih kategorija prihoda i rashoda, u sljedećoj tablici je na temelju apsolutnih iznosa pojedinih kategorija prikazana promjena koja se je dogodila u 2012. u odnosu na 2011. godinu.

Tablica 9: Promjene u приходima i rashodima Sveučilišta u Hrvatskoj u 2012. u odnosu na 2011. godinu

	UNIZG	UNIRI	UNIOS	UNIST	UNIZD	UNIDU	UNIPU
	Indeks	Indeks	Indeks	Indeks	Indeks	Indeks	Indeks
UKUPNI PRIHODI (AOP 001+251)	-1,32%	6,88%	-23,74%	-16,29%	11,19%	18,14%	3,00%
PRIHODI POSLOVANJA (AOP 047+067+090+107+114+119)	-1,32%	6,88%	-23,78%	-16,29%	11,14%	18,14%	3,00%
Pomoći iz inozemstva (darovnice) i od subjekata unutar općeg proračuna	-2,60%	9,37%	52,32%	21,71%	-17,44%	94,52%	-0,48%
Prihodi od upravnih i administrativnih pristojbi, pristojbi po posebnim propisima i naknada	-25,88%	30,27%	-27,42%	-68,19%		-9,92%	0,79%
Prihodi od prodaje proizvoda i robe te pruženih usluga i prihodi od donacija	-43,80%	-8,87%	78,99%	87,07%	21,81%	9,68%	-23,24%
Prihodi iz proračuna	12,76%	7,36%	-26,38%	-27,61%	7,58%	22,38%	5,72%
UKUPNI RASHODI (AOP 132+303)	26,97%	20,71%	-25,91%	-8,88%	6,96%	-7,89%	2,84%
RASHODI POSLOVANJA (AOP 133+145+178+197+205+217+224)	20,21%	3,27%	13,85%	15,57%	6,95%	12,62%	2,09%
Rashodi za zaposlene	1,76%	12,08%	12,00%	12,41%	7,15%	5,76%	4,86%
Materijalni rashodi	23,88%	-14,10%	12,04%	19,51%	5,99%	17,11%	-5,63%
Rashodi za nabavu nefinancijske imovine	425,60%	123,29%	-60,50%	-22,78%	7,21%	-36,08%	34,72%

Izvor: Izradila autorica prema: Ministarstvo financija Republike Hrvatske (MFIN) (2013) – Temeljni financijski izvještaji javnih visokih učilišta u periodu od 2011. – 2012.

U analizi promjene ukupnih prihoda i rashoda uključene su one stavke koje su pokazale značajniji udio u ukupnim приходima i rashodima. Ograničenje analize financijskih izvješća predstavlja nemogućnost povezivanja izvora financiranja s pojedinim vrstama rashoda i programima koje izvode visoka učilišta. Takva informacija pružila bi uvid u opravdanost raspolaganja izvorima financiranja. Vidljiva je značajna razlika u kretanju pojedinih kategorija prihoda i rashoda. Izuzev Sveučilišta u Splitu i Osijeku kojima su prihodi iz proračuna značajno porasli, ostala sveučilišta suočila su se s padom spomenute kategorije. Izuzev Sveučilišta u Zagrebu i Puli, zabilježen je pad vlastitih prihoda kod ostalih sveučilišta. Pritom su se rashodi djelomično kretali usporedno s kretanjem prihoda.

Visoko obrazovne institucije imaju obvezu korištenja vlastitih prihoda sukladno pravnoj regulativi. Ovisno o aktivnostima, izvori vlastitih sredstava mogu biti školarine, znanstveni i stručni projekti, programi stalnog usavršavanja, donacije i pomoći te iznajmljivanje prostora i opreme. Udio od 10% do 60% prihoda mora biti namijenjen unaprjeđenju edukacijskih aktivnosti. Spomenuto se odnosi i na kupnju opreme, literature te na investiranje, što je detaljnije prikazano u Tablici 10 (Bajo, 2003). Pravilnici koji visokim učilištima propisuju i uređuju način raspodjele vlastitih prihoda su: Pravilnik o osnovama financiranja visoke naobrazbe na javnim visokim učilištima (1996) i Pravilnik o mjerilima i načinu korištenja prihoda javnih visokih učilišta i javnih znanstvenoistraživačkih instituta ostvarenih na tržištu od obavljanja svoje djelatnosti (1994).

Većini visokih učilišta u Hrvatskoj školarine predstavljaju najvišu stavku vlastitih prihoda. Pritom visoka učilišta najmanje 40% prihoda ostvarene tim putem trebaju usmjeravati ka unapređenju djelatnosti, dok se preostalim dijelom trebaju podmiriti troškovi izvedbe programa visokih učilišta te troškovi poslovanja. Visoka učilišta su slobodna ustrojavati i izvoditi programe stalnog usavršavanja studenata. Pritom 40% tih prihoda treba namijeniti unapređenju djelatnosti, dok se ostatak prihoda može iskoristiti za plaćanje rada izvan normirane redovne djelatnosti. Visoka učilišta također imaju mogućnost da ugovaraju i izvode znanstvene i stručne programe i projekte. Pritom se troškovi projekata i programa u potpunosti moraju pokriti iz prihoda koje ostvaruju. Tu se prvenstveno misli na podmirenje troškova izvedbe programa u okviru troškova poslovanja te plaćanje potrebnog rada izvan normirane djelatnosti. Također, 10% prihoda potrebno je iskoristiti za unapređenje same djelatnosti. Postoji mogućnost da visoka učilišta iznajme dio prostora koji im nije potreban za neometano obavljanje djelatnosti. Minimalno 60% prihoda od najma potrebno je iskoristiti za unapređenje djelatnosti, dok se

preostalih, maksimalnih 40%, treba iskoristiti za podmirenje troškova poslovanja. Postoji i mogućnost donacija i drugih pomoći visokim učilištima. Ukoliko od strane donatora nije definirana namjena spomenutih sredstava, najmanje se 60% sredstava ostvarenih tim putem treba iskoristiti za unapređenje osnovne djelatnosti (Bajo (2003), Pravilnik o osnovama financiranja visoke naobrazbe na javnim visokim učilištima (1996), Pravilnik o mjerilima i načinu korištenja prihoda javnih visokih učilišta i javnih znanstvenoistraživačkih instituta ostvarenih na tržištu od obavljanja svoje djelatnosti (1994)).

Tablica 10: Raspodjela vlastitih prihoda visokih učilišta u Republici Hrvatskoj

Izvor vlastitih prihoda	Raspodjela na troškove	%
Školarina	unapređenje djelatnosti visokog učilišta (nabavka, oprema, literatura, investicije)	najmanje 40%
	podmirenje troškova izvedbe programa visokog školstva	dio preostalih sredstava
	troškovi poslovanja (rad izvan normirane djelatnosti)	dio preostalih sredstava
Program stalnog usavršavanja	unapređenje djelatnosti visokog učilišta	najmanje 40%
	podmirenje troškova poslovanja	dio preostalih sredstava
Znanstveni i stručni projekti	unapređenje djelatnosti visokog učilišta ili instituta	najmanje 10%
	podmirenje troškova izvedbe programa u okviru troškova poslovanja	dio preostalih sredstava
	plaćanje potrebnog rada izvan normirane djelatnosti	dio preostalih sredstava
Iznajmljivanje prostora	unapređenje djelatnosti visokog učilišta ili instituta	najmanje 60%
	podmirenje troškova poslovanja	najviše 40%
Donacije i pomoći	unapređenje osnovne djelatnosti visokog učilišta ili instituta	najmanje 60%

Izvor: Bajo, A. (2003) „Financiranje visokog školstva i znanosti“, Institut za javne financije, Zagreb, Pravilnik o mjerilima i načinu korištenja prihoda javnih visokih učilišta i javnih znanstvenoistraživačkih instituta ostvarenih na tržištu od obavljanja svoje djelatnosti, Ministarstvo financija (NN 92/94).

U današnje vrijeme, kada su Hrvatska i svijet suočeni s gospodarskom krizom, postalo je još važnije razvijati visokoobrazovni sustav koji ima sposobnost pokrenuti društvene i gospodarske promjene. Hrvatsko visoko obrazovanje treba se prilagoditi novim zahtjevima Europe koji bi doveli do stvaranja novih, kvalitetnih i kreativnih generacija stručnjaka koje bi bile ključni faktor gospodarskog rasta i razvoja.

2.3.3. Financiranje znanstvene djelatnosti u Europskoj uniji i Republici Hrvatskoj

Prema Zakonu o znanstvenoj djelatnosti i visokom obrazovanju (2003), pod pojmom znanstvene djelatnosti obuhvaćena su sva znanstvena i razvojna istraživanja. Samim zakonom ne vrši se razgraničavanje po pitanju financiranja visokih učilišta temeljem obavljanja obrazovne ili znanstvene djelatnosti. U istraživanju (Cerović, Arbula (2012), Cerović, Arbula Blecich, Štambuk (2013)) dokazano je kako znanstvena djelatnost ima ključnu ulogu na kvalitetu studiranja s utjecajem od 27%. Snažniji utjecaj jedino ima nastavni rad koji na kvalitetu studiranja djeluje s 42%. Sukladno navedenom, potrebno je veću pažnju posvetiti financiranju znanstvene djelatnosti jer je ono ključno za njezin napredak i posljedično, kvalitetu institucije.

Zakon o znanstvenoj djelatnosti i visokom obrazovanju (2003) definira financiranje znanstvene djelatnosti sa strane znanstvenih projekata, kolaborativnih znanstvenih programa, suradničkih mjesta i znanstvene opreme i to putem raspisanih natječaja. Ministar propisuje kriterije i sve potrebne postupke vezane za financiranje znanstvenih projekata na temelju prijedloga Nacionalnog vijeća za znanost. U vrednovanju se u obzir uzimaju prioritetna istraživanja unutar znanstvenih područja te ona trebaju biti od interesa gospodarstvu, društvu i državi općenito.

Ulaganja u istraživanje i razvoj u Hrvatskoj vrlo su niska (manje od 1% udjela u BDP-u) i od 2000. godine u konstantnom su padu, prvenstveno zbog smanjenog udjela financiranja od strane poslovnog sektora. Unatoč poticajnim mjerama za jačanje suradnje između poslovnog sektora i znanstvenih institucija, iz godine u godinu, rezultati su sve lošiji. 2000. godine izdvajanja poslovnog sektora iznosila su 0,48% BDP-a, a jedanaest godina kasnije svega 0,34% BDP-a (MZOS, 2013). Nezadovoljavajuće stanje još je više uočljivo kada se podaci za Hrvatsku usporede s onima Europske unije gdje, ne samo da je taj udio znatno veći nego u Hrvatskoj,

nego je on i u konstantnom porastu. Nordijske zemlje s preko 3% udjela izdataka za IiR u BDP-u su na vrhu Europe (tablica 11 i grafikon 2).


Tablica 11: Izdaci za istraživanje i razvoj od 2002. do 2013. kao udio u BDP – u izabranim zemljama Europe

	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013
EU (28)	1,81	1,8	1,76	1,76	1,78	1,78	1,85	1,94	1,93	1,97	2,01	2,01
Belgija	1,89	1,83	1,81	1,78	1,81	1,84	1,92	1,97	2,05	2,15	2,24	2,28
Bugarska	0,47	0,47	0,48	0,45	0,45	0,44	0,46	0,51	0,59	0,55	0,62	0,65
Češka	1,1	1,15	1,15	1,17	1,23	1,31	1,24	1,3	1,34	1,56	1,79	1,91
Danska	2,44	2,51	2,42	2,39	2,4	2,51	2,78	3,07	2,94	2,97	3,02	3,06
Njemačka	2,42	2,46	2,42	2,43	2,46	2,45	2,6	2,73	2,72	2,8	2,88	2,85
Estonija	0,72	0,77	0,85	0,92	1,12	1,07	1,26	1,4	1,58	2,34	2,16	1,74
Irska	1,06	1,13	1,18	1,2	1,21	1,24	1,39	1,63	1,62	1,53	1,58	n/d
Španjolska	0,96	1,02	1,04	1,1	1,17	1,23	1,32	1,35	1,35	1,32	1,27	1,24
Francuska	2,17	2,11	2,09	2,04	2,05	2,02	2,06	2,21	2,18	2,19	2,23	2,23
Hrvatska	0,95	0,95	1,03	0,86	0,74	0,79	0,88	0,84	0,74	0,75	0,75	0,81
Italija	1,08	1,06	1,05	1,05	1,09	1,13	1,16	1,22	1,22	1,21	1,27	1,26
Cipar	0,28	0,32	0,34	0,37	0,39	0,4	0,39	0,45	0,45	0,46	0,43	0,48
Latvija	0,41	0,36	0,4	0,53	0,65	0,56	0,58	0,45	0,6	0,7	0,66	0,6
Mađarska	0,99	0,92	0,87	0,93	0,99	0,97	0,99	1,14	1,15	1,2	1,27	1,41
Malta	0,25	0,24	0,49	0,53	0,58	0,55	0,53	0,52	0,64	0,7	0,86	0,85
Nizozemska	1,77	1,81	1,82	1,81	1,77	1,7	1,65	1,69	1,72	1,89	1,97	1,98
Austrija	2,07	2,18	2,17	2,38	2,37	2,43	2,59	2,61	2,74	2,68	2,81	2,81
Poljska	0,56	0,54	0,56	0,57	0,55	0,56	0,6	0,67	0,72	0,75	0,89	0,87
Portugal	0,72	0,7	0,73	0,76	0,95	1,12	1,45	1,58	1,53	1,46	1,37	1,36
Rumunjska	0,38	0,38	0,38	0,41	0,45	0,52	0,57	0,46	0,45	0,49	0,48	0,39
Slovenija	1,44	1,25	1,37	1,41	1,53	1,42	1,63	1,82	2,06	2,43	2,58	2,59
Slovačka	0,56	0,56	0,5	0,49	0,48	0,45	0,46	0,47	0,62	0,67	0,81	0,83
Finska	3,26	3,3	3,31	3,33	3,34	3,35	3,55	3,75	3,73	3,64	3,42	3,31
Švedska	n/d	3,61	3,39	3,39	3,5	3,26	3,5	3,42	3,22	3,22	3,28	3,3
UK	1,72	1,67	1,61	1,63	1,65	1,69	1,69	1,75	1,69	1,69	1,63	1,63
Norveška	1,63	1,68	1,55	1,48	1,46	1,56	1,56	1,72	1,65	1,63	1,62	1,66

Izvor: Eurostat (2015b): Research and development expenditure, by sectors of performance % of GDP dostupno na: <http://ec.europa.eu/eurostat/tgm/table.do?tab=table&init=1&language=en&pcode=tsc00001&plugin=1> (15.07.2015)

Kako bi se bolje ilustrirala razina izdataka Hrvatske u IiR, sljedećim grafikonom usporedno su prikazani ukupni izdaci za IiR Republike Hrvatske i prosjeka Europske unije (28).

Grafikon 1: Izdaci za istraživanje i razvoj od 2002. do 2013. kao udio u BDP – usporedni prikaz RH i prosjeka EU (28)




Izvor: Eurostat (2015b): Research and development expenditure, by sectors of performance % of GDP dostupno na: <http://ec.europa.eu/eurostat/tgm/table.do?tab=table&init=1&language=en&pcode=tsc00001&plugin=1> (15.07.2015)

Udio izdvajanja za IiR predstavlja jasan indikator razvijenosti same države. Po pitanju financiranja Hrvatska znatno zaostaje za Europom. Kod ulaganja u obrazovanje vide se pozitivni pomaci, ali je ulaganje u istraživanje i razvoj zapostavljeno. Obzirom da je znanost pokretač razvoja, Republika Hrvatska bi trebala napraviti ozbiljnije pomake u segmentu njezinog financiranja kako bi se približila prosjeku EU.

Pred Hrvatsku, kao i pred ostale članice Europske unije stavljeni su okvirni uvjeti u području istraživanja i inovacija. Lisabonskom strategijom tako je predviđeno dostizanje cilja ulaganja u IiR u iznosu od 3% BDP – a (označeno crvenom linijom na grafikonu 2) te odnos između privatnih i javnih ulaganja 2:1 do 2010. godine. Navedeno se ipak pokazalo kao preveliki izazov za većinu članica EU, pa tako i za Hrvatsku jer su i u 2013. godini ostale daleko ispod zadane granice (grafikon 2). Granica određena Lisabonskom strategijom ostala je cilj i Europskoj strategiji do 2020. Unatoč nedostizanju ciljeva definiranih Lisabonskom strategijom, važno je

ustrajati u približavanju istima na način da se djeluje u specifičnim područjima od stvaranja ljudskog kapitala, povezivanjem znanosti i gospodarstva te kreiranju zajedničkog europskog znanstvenog prostora (MZOS, 2008).


Grafikon 2: Usporedni prikaz ulaganja u IiR kao % BDP-a Hrvatske i izabranih zemalja Europe u 2013. godini



Izvor: Eurostat (2015b): Research and development expenditure, by sectors of performance % of GDP dostupno na: <http://ec.europa.eu/eurostat/tgm/table.do?tab=table&init=1&language=en&pcode=tsc00001&plugin=1> (15.07.2015)

Lisabonska strategija sugerira, kao prioritetni cilj, omjer od 2:1 između izdvajanja iz poslovnog i javnog sektora za IiR. Grafikon 3 prikazuje usporedbu ulaganja u istraživanje i razvoj prema izvorima financiranja u Hrvatskoj i odabranim zemljama Europe. U ostale izvore ubraja se privatni neprofitni sektor i sektor visokog obrazovanja.

Grafikon 3: Ulaganja U IiR prema izvoru sredstava za Hrvatsku i izabrane zemlje Europe u 2013. godini




Izvor: Eurostat (2015a): Gross domestic expenditure on R&D (GERD) by source of funds, % of total GERD, dostupno na: <http://epp.eurostat.ec.europa.eu/tgm/refreshTableAction.do?tab=table&plugin=1&pcode=tsc00031&language=en> , pregledano (15.07.2015)

U većini promatranih zemalja izdvajanja za IiR podjednako su distribuirana između poslovnog i državnog sektora. Jedino Danska, Finska, Švedska i Slovenija zadovoljavaju omjer od 2:1 između izdvajanja iz poslovnog i državnog sektora za IiR. U Hrvatskoj se za IiR 42,8% izdvaja iz poslovnog sektora, 39,7% iz privatnog sektora, 15,5% iz inozemnih ulaganja te 2% iz ostalih izvora.

Financiranje znanosti u Hrvatskoj velikim dijelom vrši se putem projekata. U prilog tablici 6 u kojoj je vidljiv pad ulaganja u IiR ide i podatak da je Ministarstvo od 2007. do 2010 financiralo 2.314 znanstvenih projekata. Taj broj je 2010. godine iznosio 2.089 projekata, a dvije godine kasnije svega 1.923 projekta. Hrvatska za Europskom unijom zaostaje i kada je u pitanju objavljivanje međunarodno priznatih znanstvenih radova po broju stanovnika. Iako je zabilježen porast broja objavljenih znanstvenih publikacija (2009. godine 4.307, a 2010. godine 4.988), nizak je udio njih objavljen u najcitatiranim publikacijama. U zemljama članicama EU godišnje se prosječno objavljuje 11% znanstvenih publikacija u 10% najcitatiranih publikacija u pripadajućem znanstvenom području dok je u Hrvatskoj to svega oko 3% (MZOS, 2013a).


Na sljedeća dva grafikona prikazan je broj objavljenih istraživačkih radova. Na grafikonu 4 prikazani su objavljeni istraživački radovi na razini svih sektora ukupno (poslovni sektor, državni i privatni neprofitni sektor te visoko obrazovanje), društvenim znanostima na razini svih sektora ukupno (sva znanstvena područja ukupno) te ekonomiji na razini svih sektora ukupno. Na grafikonu 5 prikazano je isto, ali na razini visokog obrazovanja. Na oba grafikona broj objavljenih radova prikazan je temeljem mjesta na kojem su objavljeni.

Grafikon 4: Objavljeni istraživački radovi u Hrvatskoj prema mjestu objavljivanja na razini svih sektora ukupno, područje društvenih znanosti na razini svih sektora ukupno, polje ekonomija na razini svih sektora ukupno u 2013. godini



Izvor: Državni zavod za statistiku Republike Hrvatske (DZS) (2015): Istraživanje i razvoj u 2013., Statistička izvješća

Grafikon 5: Objavljeni istraživački radovi u Hrvatskoj prema mjestu objavljivanja u visokom obrazovanju, područje društvenih znanosti, polje ekonomija u 2013. godini




Izvor: Državni zavod za statistiku Republike Hrvatske (DZS) (2015): Istraživanje i razvoj u 2013., Statistička izvješća

Po pitanju objavljivanja istraživačkih radova, prema sektorima, visoka učilišta premoćno vode s preko 60% udjela u ukupnom broju objavljenih istraživačkih radova. Slijede javni znanstveni instituti i na kraju poslovna poduzeća sa skromnim brojem objavljenih radova. Također, prema mjestu publiciranja, iako su vlastite publikacije i druge publikacije u zemlji visoko zastupljene, udio inozemnih publikacija u ukupnom broju je gotovo 48% u sektoru visokog obrazovanja, dok je na razini svih sektora njihov udio 38%. Inozemne publikacije u polju ekonomije i na razini svih sektora ukupno i na razini visokog obrazovanja zastupljene su s nešto više od 39%.

Visoko obrazovanje i znanost u Republici Hrvatskoj usko su vezani jer je većina nastavnog osoblja na visokoobrazovnim institucijama ujedno i u sustavu znanosti kao istraživač. U 2013. od ukupno 8.106 zaposlenih u sustavu visokog obrazovanja, 5.949 osoba bili su istraživači što predstavlja udio od 73,4%. Od ukupnog broja zaposlenih, 19,3% dolazi iz društvenih znanosti dok broj istraživača iz društvenih znanosti čini 22,4% ukupnog broja istraživača.

Grafikon 6: Udio zaposlenih u društvenim znanostima i visokom obrazovanju prema vrsti zaposlenosti u Republici Hrvatskoj u 2013. godini



Izvor: Državni zavod za statistiku Republike Hrvatske (DZS) (2015): Istraživanje i razvoj u 2013., Statistička izvješća

Sveobuhvatni cilj znanstvene i visokoobrazovne politike Hrvatske je stvaranje tzv. društva znanja, društva koje se stvara temeljem međudjelovanja poslovnog, sveučilišnog i državnog sektora. U stvaranju društva znanja moraju se uključiti potencijali i resursi gospodarskog i državnog sektora koji će poticati istraživanje i razvoj znanosti te stvaranje novih i poboljšanih tehnologija, proizvoda ili usluga na visokim učilištima, institutima, istraživačkim jedinicama poduzeća, a sve radi jačanja gospodarstva i povećanja konkurentnosti na međunarodnom tržištu.

Omjer privatnog i javnog ulaganja u istraživanje u Hrvatskoj je nepovoljan jer se premalo izdvaja iz privatnih izvora (grafikon 3), a ukupna količina financijskih sredstava koja je na raspolaganju institucijama i istraživačima znatno je manja nego u razvijenim europskim državama (tablica 11, grafikon 1), čime je i kompetitivnost hrvatskih istraživača značajno umanjena. Porastom ulaganja u visoko obrazovanje i znanost, koja su u Republici Hrvatskoj značajno manja nego u državama Europske unije, potaklo bi se stvaranje društva znanja koje bi potaknulo brži i intenzivniji razvoj države i približilo je prosjeku zemalja Europske unije. Od hrvatskog znanstvenog sustava očekuje se da, zajedno s visokim obrazovanjem, bude pokretač društvenog i gospodarskog rasta i razvoja.

2.4. PRORAČUNSKO RAČUNOVODSTVO U SEGMENTU VISOKOG OBRAZOVANJA

Kako bi se na temeljit i sveobuhvatan način pratila proračunska potrošnja i aktivnosti državnih sastavnica razvijeno je proračunsko računovodstvo. Državne jedinice temeljem toga imaju specifičan okvir za financijsko izvještavanje. Kako se u poslovanju javnoga sektora prema definiciji, isključuje konkurencija i tržišno djelovanje, postoji odsutnost dobiti kao primarnog cilja poslovanja. Financijska sredstva korisnika državnog proračuna su ograničena i njihova visina je definirana proračunom koji se donosi na godišnjoj razini. Visoka učilišta se, pored financiranja iz proračuna, djelomično financiraju i iz drugih izvora. Postoji tendencija, kako u svijetu, tako i u Hrvatskoj, da se udio financiranja neproračunskim sredstvima povećava. Tim sredstvima se prvenstveno financiraju nastavna i znanstveno-istraživačka djelatnost. Proračunsko računovodstvo ne predstavlja samo alat evidencijskog sustava nego ima ključnu ulogu u procesu upravljanja i nadzora od strane njegovih korisnika. Proračunsko računovodstvo u Republici Hrvatskoj usmjereno je prvenstveno vanjskom izvještavanju, a njegov normativni okvir uređen je Zakonom o proračunu (2008) čime je stvorena platforma za razvoj proračunskog računovodstva.

Prema Pravilniku o proračunskom računovodstvu i računskom planu (2008) računski plan proračunskih korisnika sastoji se od deset razreda navedenih u tablici:

Tablica 12: Struktura računskog plana proračunskog računovodstva u Republici Hrvatskoj

Broj razreda	Naziv razreda
0	Nefinancijska imovina
1	Financijska imovina
2	Obveze
3	Rashodi poslovanja
4	Rashodi za nabavu nefinancijske imovine
5	Izdaci za financijsku imovinu i otplate zajmova
6	Prihodi poslovanja
7	Prihodi od prodaje nefinancijske imovine
8	Primitci od financijske imovine i zaduživanja
9	Vlastiti izvori

Izvor: Pravilnik o proračunskom računovodstvu i računskom planu (NN 87/08, 136/12, 124/14)

Financijski izvještaji sastavljaju se minimalno jednom godišnje. S obzirom da su te informacije sintetizirane i sveobuhvatne te namijenjene prvenstveno vanjskim korisnicima, one unutarnjim (internim) korisnicima često nisu dovoljne. Informacije dobivene iz financijskih izvještaja često je potrebno nadopuniti dodatnim informacijama nužnim za donošenje odluka u procesu upravljanja. Putem tih informacija moguće je imati transparentniji i detaljniji uvid u interne procese organizacije i pratiti, proučavati i planirati njezine troškove. Interes javnosti za boljim i detaljnijim uvidom u rad menadžmenta poduzeća i institucija javnoga sektora postaje sve izraženiji zbog čega upravljačko i troškovno računovodstvo u javnom sektoru sve više dobivaju na značenju. Potonje je postalo preduvjet za kvalitetno upravljanje, analizu i nadzor poslovanja te nužan alat za dobivanje potrebnih informacija bez kojih gotovo nije moguće zadovoljiti sve veće zahtjeve javnosti i provoditi nadzor uspješnosti poslovanja. (Vašiček, Dražić Lutilsky, 2011). Također, potvrđeno je da nedovoljno korištenje instrumenata i postupaka troškovnog i upravljačkog računovodstva u javnom sektoru ima utjecaj na kvalitetu donesenih odluka koje dovode do brojnih negativnih ekonomskih i financijskih implikacija (Dražić Lutilsky, 2006).

Uloga troškovnog računovodstva šira je od one povijesne prema kojoj se radi o utvrđivanju vrijednosti zaliha ili drugih oblika imovine za potrebe financijskog računovodstva. Ona se očituje i kroz proces planiranja (budžetiranja), kontrolu i smanjenje troškova, određivanje cijena i naknada, vrednovanje poslovnih rezultata, evaluiranje programa te različitosti kod izbora ekonomskih odluka (IFAC-PSC (2000, p. 7) prema Vašiček i dr. (2011, p.19))

Unatoč važnosti korištenja instrumenata troškovnog i upravljačkog računovodstva, njihova zastupljenost je ipak često zanemarena u javnom sektoru. Prvi pokušaji uvođenja koncepta troškovnog računovodstva za sveučilišta dogodili su se 70 tih godina 20. stoljeća na svega nekoliko sveučilišta te su se pokazali neuspješnima (Küpper, 2013). Tek u novije vrijeme ovaj koncept se počinje više zagovarati. I u Republici Hrvatskoj postoji niska razina korištenja instrumenata troškovnog i upravljačkog računovodstva u javnom sektoru (Dražić Lutilsky, 2006). Ipak, kao primjeri država koje su implementirale troškovno i upravljačko računovodstvo u svoj javni sektor mogu se navesti Novi Zeland, Australija, Velika Britanija i Kanada (Vašiček, i dr., 2011). Kao razlozi zbog kojih se troškovno računovodstvo ne koristi dovoljno u javnom sektoru navodi se sljedeće (IFAC-PSC (2000) prema Vašiček i dr. (2011)):

- javne usluge dostupne su svim građanima bez plaćanja naknade;
- nije moguće procijeniti i izračunati vrijednost pojedinih troškova, a ukoliko su oni i poznati često nisu definirani kriteriji procjene pojedinih aktivnosti;

- različiti projekti i programi doneseni od strane vlada gotovo su isključivo produkt političkih odluka u kojima troškovi imaju marginalni značaj;
- kontrola izvora proračunskih sredstava, a ne zapravo nastali troškovi, predstavlja primarni interes zakonodavca zbog funkcioniranja proračuna po načelu novčanih tokova.

Troškovno računovodstvo, između ostaloga, koristi prikupljene i obrađene informacije o troškovima kao temelj procjene visine i vrste budućih troškova pri planiranju i pripremi proračuna. Temeljem tih informacija moguće je vršiti kontrolu nad troškovima, utvrditi odstupanja od plana ili standarda, te, ukoliko je potrebno, poduzeti potrebne mjere za smanjenje istih. Upravljačko i troškovno računovodstvo su izravno odgovorni za efikasnost i efektivnost pružanja usluga i zadovoljenja javnih potreba jer upravo informacije koje oni pružaju dovode do sustavnog rasta kvalitete računovodstvenih informacija koje onda koriste menadžmentu pri upravljanju i donošenju odluka. (Vašiček i dr., 2011)

2.4.1. Osnovne odrednice proračunskog računovodstva u segmentu visokog obrazovanja

Prema Zakonu o proračunu Republike Hrvatske (2008), proračun se definira kao akt koji služi za procjenjivanje visine prihoda i primitaka i utvrđivanje razine rashoda i izdataka jedne godine. On predstavlja okvir (iskazan u novčanim jedinicama) koji služi kao smjernica za buduće djelovanje, a donosi se za određeno proračunsko razdoblje koje je u praksi najčešće jedna godina. Zakonom o proračunu određuje se sve vezano za proračun opće države od faze planiranja i izrade, pa sve do njegovog donošenja i samog izvršenja. Proračun opće države sastoji se od tri razine, i to, državnog proračuna, proračuna izvanproračunskih fondova i proračuna jedinica lokalne uprave i samouprave. On pokazuje razinu prihoda koje je država prikupila i način na koji su ti prihodi potrošeni. Proračun se sastoji od općeg (Račun prihoda i rashoda i Račun financiranja) i posebnog dijela (plan rashoda i izdataka korisnika proračuna koji su raspoređeni po organizacijskoj klasifikaciji, tj. korisnicima i po tekućim i razvojnim programima za tekuću proračunsku godinu) i plana razvojnih programa. Unutar općeg dijela proračuna posebnu važnost ima Račun financiranja jer se u njemu iskazuju zaduživanja državnog proračuna i jedinica lokalne i regionalne samouprave. Kod proračuna vlada temeljno pravilo očuvanja proračunske ravnoteže, a to je da ukupni rashodi fiskalnog razdoblja budu jednaki ukupnim prihodima fiskalnog razdoblja uvećanima za prenesene viškove prihoda prethodnih razdoblja. Najvažniji, odnosno najviši, prihodi i primici države su oni nastali

oporezivanjem, potom dobivene potpore te primitci nastali zaduživanjem u zemlji ili inozemstvu. Što se tiče rashoda proračuna, njihova osnovna podjela je na tekuće, kapitalne i posudbe umanjene za otplate (Institut za javne financije, 2003) Proračun mora pružiti informaciju vezanu za razinu raspoloživih sredstava, plan ostvarivanja prihoda i njihovog trošenja u tijeku proračunskog razdoblja te načina njihove raspodjele ovisno o pojedinim javnim funkcijama

Proračun ima više ciljeva koji proizlaze iz temeljne dužnosti države da zadovolji javne potrebe. Kao osnovni ciljevi proračuna koji funkcioniraju bez međusobnog isključivanja izdvajaju se sljedeći: (Keser i dr., 2000., p. 17.)

- korištenje proračunskog instrumentarija kako bi se osigurala provedba makroekonomske politike te postigao željeni stupanj i dinamika gospodarske aktivnosti;
- održavanje stabilnosti gospodarstva, kontrola inflacije i ostvarivanje pune zaposlenosti;
- osiguravanje određene razine zadovoljenja javnih potreba sukladno predviđanju i planu;
- ostvarivanje očekivane razine prihoda;
- kontrola trošenja javnih (državnih) sredstava;
- organizacija računovodstvene evidencije koja treba osigurati točne i ažurne podatke o iznosima primitaka i izdataka. Pritom se kao funkcija računovodstvene evidencije ističe osiguravanje nadzora nad izvršavanjem proračuna;
- koristeći informacije dobivene računovodstvenom evidencijom, omogućavanje utvrđivanja odstupanja ostvarenog od očekivanog koje bi pravovremeno trebalo upozoriti na potencijalne probleme;
- implementacija sustava proračuna prilagođenog i primjerenog kako političkoj, tako i ekonomskoj te socijalnoj slici države. Kao takvoga trebalo bi ga se moći usporediti s drugim zemljama.

Računovodstvena načela točnosti, istinitosti, pouzdanosti te pojedinačnog iskazivanja pozicija primjenjuju se i u okviru proračunskog računovodstva. Ono je u Republici Hrvatskoj primarno je uređeno Zakonom o proračunu (2008), ali se u području samog računovodstva i izvještavanja dodatno dopunjuje Pravilnikom o proračunskim klasifikacijama (2010), Pravilnikom o proračunskom računovodstvu i računovodstvenom planu (2008) i Pravilnikom o financijskom izvještavanju u proračunskom računovodstvu (2008). Od 2002. godine u proračunskom računovodstvu u Republici Hrvatskoj prestalo se primjenjivati načelo novčanog tijeka prema

kojem su se prihodi evidentirali u trenutku naplate, a rashodi u trenutku kada su plaćeni. Ovaj koncept zamijenjen je tzv. modificiranim načelom nastanka događaja. Ovo načelo podrazumijeva da se prihodi priznaju u trenutku novčanog primitka, a rashodi u trenutku nastanka poslovnih događaja bez obzira je li došlo do novčanog izdatka.

Primarni izvor financiranja obrazovanja su proračunska sredstava, a visoko obrazovanje i znanost se iz aspekta proračunskih klasifikacija ubrajaju u sustav proračunskih korisnika u okviru funkcije obrazovanja kao njezina podfunkcija (Maletić, Jakir-Bajo (2005). U proračunske korisnike iz područja znanosti i visokog obrazovanja u okviru MZOS ubrajaju se: (NN 73/14)

- javni znanstvenoistraživački instituti koji su nositelji znanstvenoistraživačkog programa,
- javna visoka učilišta – sveučilišta koja objedinjavaju fakultete, veleučilišta i visoke škole

Kao proračunski korisnici, gore navedene institucije, dužne su primjenjivati načela proračunskog računovodstva pri računovodstvenom praćenju i proučavanju poslovnih promjena.

Mjerenje i priznavanje ekonomskih kategorija subjekata u visokom obrazovanju

Pod pojmom ekonomskih kategorija subjekata javnog sektora, prije svega se misli na osnovne elemente sustava proračuna i to proračunske prihode i primitke te proračunske rashode i izdatke. Ove ekonomske kategorije povezuje državna riznica.

Proračunski prihodi i primitci:

Prema Pravilniku o proračunskom računovodstvu i računskom planu (2008, čl. 20) prihod proračunskih korisnika definiran je kao „*povećanje ekonomskih koristi tijekom izvještajnog razdoblja u obliku priljeva novca i novčanih ekvivalenata*“. Pod pojmom proračunskih primitaka podrazumijevaju se „*priljevi novca i novčanih ekvivalenata po svim osnovama*“. Prihodima i primicima podmiruju se određene vrste rashoda i izdataka s točno određenom namjenom te se stoga ove kategorije nazivaju i izvorima financiranja. Prema Pravilniku temeljna klasifikacija prihoda je na prihode poslovanja (prihodi od poreza, prihodi od doprinosa, pomoći, prihodi od imovine, prihodi od upravnih i administrativnih pristojbi, pristojbi po posebnim propisima i naknada, prihodi od prodaje proizvoda i robe te pruženih

usluga i prihode od donacija, prihodi iz proračuna te kazne, upravne mjere i ostali prihodi i prihodi od prodaje).

U državnom proračunu najveći dio prihoda prikupljen je putem poreza. Proračunska sredstva se svake godine prema definiranom planu proračuna raspoređuju na proračunske korisnike u koje se ubraja i visoko obrazovanje

Priznavanje prihoda i rashoda vrši se prema modificiranom načelu nastanka događaja. Modificirano načelo nastanka događaja podrazumijeva da se: (Pravilnik o proračunskom računovodstvu i računskom planu, 2008, čl. 20)

- *„ne iskazuje rashod amortizacije nefinancijske dugotrajne imovine,*
- *ne iskazuju prihodi i rashodi uslijed promjena vrijednosti nefinancijske imovine,*
- *prihodi priznaju u izvještajnom razdoblju u kojemu su postali raspoloživi i pod uvjetom da se mogu izmjeriti,*
- *rashodi priznaju na temelju nastanka poslovnog događaja (obveza) i u izvještajnom razdoblju na koje se odnose neovisno o plaćanju,*
- *rashodi za utrošak kratkotrajne nefinancijske imovine priznaju se u trenutku nabave i u visini njene nabavne vrijednosti. Iznimno, u djelatnosti zdravstva te u obavljanju vlastite trgovačke i proizvođačke djelatnosti rashodi za kratkotrajnu nefinancijsku imovinu iskazuju se u trenutku stvarnog utroška odnosno prodaje,*
- *za donacije nefinancijske imovine iskazuju se prihodi i rashodi prema procijenjenoj vrijednosti.“*

Prema modificiranom načelu nastanka događaja prihodi se priznaju u trenutku njihove naplate, odnosno priljeva novčanih sredstava u obračunskom razdoblju, što bi značilo da se fakturirani prihodi knjiže na računima 96 i 97 kao obračunati prihodi. U trenutku njihove naplate prenose se u razred 6 ili 7 na račune prihoda (Vidović, 2012).

U visokom obrazovanju, većina prihoda proizlazi iz dva temeljna izvora. Jedan izvor su vlastiti prihodi, odnosno oni nastali poslovanjem institucije na tržištu. Drugi izvor, ujedno i najviša prihodovna stavka, su prihodi dobiveni iz državnog proračuna.

Proračunski rashodi i izdaci:

Pravilnik o proračunskom računovodstvu i računskom planu (2008, čl. 20) rashode definira kao „*smanjenja ekonomskih koristi u obliku smanjenja imovine ili povećanja obveza*“, a izdatke kao „*odljeve novca i novčanih ekvivalenata po svim osnovama*“. Rashodi i izdaci usko su vezani uz izvore financiranja (prihode i primitke) jer se temeljem njih planiraju, izvršavaju u evidentiraju u računovodstvu. Temeljna klasifikacija rashoda koju definira Pravilnik je na rashode proizašle iz poslovanja (rashodi za zaposlene, materijalni rashodi, financijski rashodi, subvencije, pomoći, naknade i ostali rashodi.) i na rashode za nabavu nefinancijske imovine (po vrstama nefinancijske imovine).

Prema modificiranom načelu nastanka događaja rashodi se priznaju u trenutku kada je nastao poslovni događaja, odnosno u trenutku stvarne potrošnje, neovisno o tome jesu li plaćeni.

Sustav nacionalnih računa navodi tri vrste rashoda državnih subjekata, a to su: (SNA, 1993 prema Dimitrić, 2007):

- rashodi nastali zbog besplatnog pružanja usluga poput onih za obranu, javno zdravstvo i školstvo, državnu administraciju i slično, tj. za sve one usluge koje ne regulira tržište svojim mehanizmima i koje iz tog razloga podliježu financiranju javnim sredstvima i regulaciji države;
- rashodi nastali radi provođenja socijalne politike na način da su se određenim kućanstvima dobra ili usluge pružale ili besplatno ili po ekonomski zanemarivim cijenama;
- rashodi nastali preraspodjelom dohotka transferiranjem sredstava ostalim institucionalnim jedinicama.

U visokom obrazovanju najveća rashodovna strana su obično izdaci za zaposlene.

Državna riznica:

Prema Zakonu o proračunu (2008, čl. 3) državna riznica se definira kao „*sustav koji organizacijski i informacijski objedinjava proračunske procese: pripremu proračuna, izvršavanje državnog proračuna, državno računovodstvo, upravljanje novčanim sredstvima i javnim dugom.*“ Ona služi kao poveznica između proračunskih prihoda i rashoda na temelju

centraliziranog tipa upravljanja javnim izdacima preko jedinstvenog novčanog računa državnog proračuna koji služi za obavljanje svih njegovih financijskih transakcija (Dražić Lutilsky, 2006). Ministarstvo financija Republike Hrvatske (2007; n.d.) unutar kojega je državna riznica i ustrojena kao upravna organizacija, ističe racionalnije trošenje javnog novca, smanjenje potreba za zaduživanjem države te rast likvidnosti poduzetničkog sektora kao pozitivne učinke uvođenja i primjene sustava državne riznice koji za cilj imaju efikasnije upravljanje javnom potrošnjom.

2.4.2. Financijsko izvješćivanje proračunskih korisnika u visokom obrazovanju

Računovodstveni sustav, kako u poduzeću, tako i u državi, dio je informacijskog podsustava. U njega ulaze prikupljeni podaci koje ono obrađuje i u oblikuje u financijske izvještaje koji služe kao podloga za donošenje odluka u poslovanju. Financijski izvještaji kao takvi predstavljaju output računovodstva. Njihova funkcija je da korisnicima pruže kvalitetne informacije koje će im pomoći u odlučivanju.

Računovodstveno izvještavanje može se promatrati s makro i mikro razine. Pod makro razinom računovodstvenog izvještavanja o javnom sektoru smatra se dio sustava društvenih računa koji se na međunarodnoj razini uređuju u okviru Sustava nacionalnih računa (SNA – eng. *System of National Accounts*) donesenog od strane Ujedinjenih naroda, Europskog sustava računa (ESA – eng. *European System of Accounts*) donesenog od strane Europske unije i Statistike državnih financija za javni sektor (GFS – Government Finance Statistics). GFS predstavlja međunarodni statistički okvir konstruiran od strane Međunarodnog monetarnog fonda sa svrhom poticanja država u prezentiranju statističkih podataka na način da oni budu međusobno usporedivi. Pod mikro razinom misli se na računovodstveno izvještavanje proračunskih i izvanproračunskih korisnika. Nacionalni propisi uređuju računovodstvo javnog sektora svake zemlje. Ti propisi se trebaju uskladiti s međunarodnim standardima financijskog izvještavanja u javnom sektoru - IPSAS (eng. *International Public Sector Accounting Standards*). Njih donosi i objavljuje Međunarodni savez računovođa – IFAC (eng. *International Federation of Accountants*) preko Odbora za međunarodne računovodstvene standarde u javnom sektoru – IPSASB (eng. *International Public Sector Accounting Standards Board*). (Dimitrić (2007), Vašiček, 2009, Vašiček, Dražić Lutilsky (2011)).

Institucije visokog obrazovanja kao proračunski korisnici dužne su sastavljati financijske izvještaje. Temeljna podjela tih financijskih izvještaja je na one vanjske (eksterne) koji se još nazivaju temeljnima i unutarnje (interne). Vanjski su namijenjeni vanjskim korisnicima, prije svega, javnosti, potom, Ministarstvu znanosti, obrazovanja i sporta, Ministarstvu financija, Državnom zavodu za statistiku i drugima, dok interni financijski izvještaji prvenstveno služe kako bi pružili informacije potrebne za upravljanje visokoobrazovnom institucijom kao korisnikom proračuna, a namijenjeni su prvenstveno menadžmentu. Financijski izvještaji namijenjeni vanjskim korisnicima definirani su zakonom te su kao takvi unificirani i jednaki za sve proračunske korisnike. Moraju biti razumljivi korisnicima i davati jasnu sliku o financijskom stanju i poslovanju poduzeća/organizacije/institucije. Unutarnji se, s druge strane, prilagođavaju institucijama temeljem njihovih specifičnosti, a sve vezano za izvještavanje donosi se unutar same institucije temeljem njezinih internih potreba. Eksternim financijskim izvještavanjem bavi se isključivo financijsko računovodstvo dok su troškovno i upravljačko računovodstvo odgovorni za provođenje internog obračuna i pružanja informacija upravljačkim strukturama koje one potom koriste kod planiranja i odlučivanja. Iako su se upravljačko i troškovno računovodstvo pokazali izuzetno korisni kao unutarnji izvori informacija, njihova uporaba je često zanemarena u javnom sektoru. Razlog tome je, između ostalog, često nefunkcioniranje i neodlučivanje javnog sektora temeljem ekonomskih pravila nego temeljem političkih odluka. Istraživanje provedeno na primjeru visokog obrazovanja u Hrvatskoj ukazuje na slabo korištenje troškovnog i upravljačkog računovodstva u tom specifičnom segmentu javnog sektora bez obzira na činjenicu da su prodekani i računovođe svjesni njegove važnosti za donošenje odluka u poslovanju. Posljedica spomenutog je neraspolaganje potrebnim informacijama za upravljanje i donošenje ekonomskih i financijskih odluka. Jedan od razloga nekorištenja troškovnog i upravljačkog računovodstva je nedovoljna informiranost Uprave visokoobrazovnih institucija o koristima informacija koje oni pružaju (Dražić Lutilsky, 2006).

Proračunsko računovodstvo po pitanju eksternog financijskog izvještavanja, za razliku od financijskog, posebno ističe važnost izvještavanja prvenstveno o načinu korištenja proračunskih sredstava. Njegova zadaća je također pružanje svih potrebnih informacija koje bi omogućile procese kontrole pri izvršenju proračuna. Informacije dobivene kroz ovaj oblik izvještavanja trebale bi jasno upućivati na uspješnost i financijski položaj proračunskog korisnika i same zemlje te omogućiti usporedivost s proračunskim sustavima drugih zemalja.

Uloga izvještaja proračunskog računovodstva u RH prvenstveno je osigurati trošenje proračunskog novca u skladu sa zakonom i predviđenom namjenom. Proračunski korisnici državnog proračuna u koje spadaju i javne visokoobrazovne ustanove dužni su sastaviti sljedeće financijske izvještaje: (Pravilnik o financijskom izvještavanju u proračunskom računovodstvu, 2008, čl.7):

1. Bilanca,
2. Izvještaj o prihodima i rashodima, primicima i izdacima,
3. Izvještaj o promjenama u vrijednosti i obujmu imovine i obveza, te
4. Bilješke uz financijske izvještaje.

Osnovna svrha bilance kod javnih institucija visokog obrazovanja je ta da pruži uvid u imovinu i obveze visokoobrazovne institucije. Za razliku od privatno orijentiranih poduzeća kod kojih vrednovanje imovine i obveza ima direktan utjecaj na ostvareni profit, kod javnih visokoobrazovnih institucija to nema značajniji utjecaj jer država prigušuje njihov financijski rizik. Kod izvještaja o prihodima i rashodima, za razliku od računa dobiti i gubitka privatnih poduzeća kod kojega postoji uzročno posljedična veza između prihoda i rashoda, kod javnih visokoobrazovnih institucija to nije slučaj. S obzirom da se outputi visokoobrazovnih institucija većinom ne prodaju na tržištu, godišnji financijski rezultat uglavnom najviše ovisi o alokaciji javnih dobara te ne može služiti kao odrednica uspjeha. U Izvještaju o promjenama u vrijednosti i obujmu imovine i obveza iskazuju se sve promjene u vrijednosti imovine (revalorizacija) te promjene u obujmu imovine i obveza. Ove promjene, iako nisu rezultat transakcija, imaju utjecaj na neto vrijednost (razlika između imovine i obveza). Bilješke uz financijske izvještaje služe kako bi dopunile i detaljnije objasnile ostale financijske izvještaje te mogu biti opisne, brojčane i kombinirane (Pravilnik o financijskom izvještavanju u proračunskom računovodstvu, 2008).

Kada je u pitanju interno financijsko izvješćivanje, ne postoje unificirana, zakonom propisana izvješća koja primjenjuju svi proračunski korisnici. U provođenju internog obračuna polazi se od specifičnosti svakog poduzeća ili institucije te se interni obračun vrši isključivo kako bi se zadovoljili interni korisnici koji potom dobivene informacije koriste u upravljanju, odlučivanju i planiranju. Iako financijska izvješća namijenjena unutarnjim korisnicima nemaju striktno propisanu formu, okvir za njih ipak postoji i ulazi u domenu troškovnog i upravljačkog računovodstva. Ovi sustavi u sklopu stvaranja i prezentiranja internih financijskih izvještaja trebaju prije svega voditi računa o vrsti poslovanja, zahtjevima menadžmenta i o

informativskom sustavu podrške. Podaci i informacije dobivene ovim putem trebaju biti razumljive i transparentne kako bi služile upravljačkim strukturama u donošenju odluka i kako bi pružale informacije koje se mogu iskoristiti i u eksternom izvještavanju.

Troškovno računovodstvo primarno je razvijeno i korišteno u poduzećima koja se bave proizvodnjom. Zbog koristi koje ovaj sustav pruža, sve se češće koristi i u drugim djelatnostima, ali uz određene promjene koje uvažavaju njihove specifičnosti. Prednosti koje ovaj sustav pruža prije svega se očituju u pružanju informacija potrebnih za planiranje i donošenje poslovnih odluka. Princip troškovnog računovodstva moguće je primjenjivati i u javnom sektoru. Njime je moguće korištenjem metoda kalkulacije kojima se troškovi raspoređuju na njihove nositelje utvrditi npr. cijenu koštanja pruženih usluga (u slučaju visokoobrazovnih institucija npr. cijenu studija) prilikom čega se moraju uvažavati specifičnosti javnoga sektora i tome prilagoditi same metode obračuna. (Vašiček, Dražić Lutilsky, 2011). Također, ono pruža informaciju o različitim aktivnostima (nastavne, znanstvene, međunarodne i druge aktivnosti koje se odvijaju na institucijama visokog obrazovanja) te inputu i outputu koji proizlazi iz tih aktivnosti. Temeljem tih informacija može se dobiti uvid u uspješno provođenje tih aktivnosti.

S obzirom da interno izvještavanje nije metodološki usklađeno s onim eksternim, na međunarodnoj razini stvorila se tendencija osiguranja jedinstvene metodologije izvještavanja. Ona bi trebala doprinijeti većoj transparentnosti i jednostavnijem korištenju internih informacija u svrhu izvještavanja vanjskih korisnika zbog standardiziranog pristupa. (Vašiček, Dražić Lutilsky, 2011)

2.5. VISOKO OBRAZOVANJE KAO DIO DRUŠTVENO ODGOVORNOG RAČUNOVODSTVA

Prihvatanjem društveno odgovornog poslovanja kao široko prihvaćenog koncepta i isticanja poduzeća koja ga primjenjuju kao primjere dobre prakse, pojavila se je potreba i za nadopunjavanjem računovodstvenog sustava kojeg koriste kako bi udovoljavao dodatnim zadacima i ciljevima. S obzirom da javna poduzeća i institucije sukladno svojem razlogu postojanja trebaju biti, prije svega, odgovorna prema poreznim obveznicima i zajednici općenito, sustav društveno odgovornog računovodstva je upravo u ovom segmentu i najčešće spominjan kao potreban. Javno dostupne informacije o javnim institucijama visokog obrazovanja često su netransparentne i nedostatne.

Tradicionalno se društvena odgovornost poduzeća na slobodnom tržištu promatrala isključivo kroz prizmu maksimizacije profita kao maksimizacije doprinosa društvu (Ramanathan, 1976). Visokoobrazovne institucije moraju djelovati u interesu više različitih dionika (država, akademsko osoblje, studenti i dr.). Sukladno tome tradicionalni računovodstveni sustav trebale bi prilagoditi svojim potrebama kako bi on bio u funkciji pružanja korisnih informacija dionicima. Kako bi to ostvarile, potrebno je u obzir uzeti vlastite odrednice poslovanja kao i vlastite mjere uspjeha (Küpper, 2013).

Društveno odgovorno računovodstvo (DOR) Mathews (1993) definira kao objavljivanje kvalitativnih i kvantitativnih informacija na dobrovoljnoj osnovi od strane poduzeća ili institucija s ciljem informiranja dionika ili utjecaja na njih. Pritom se objava kvantitativnih informacija može iskazati financijskim ili nefinancijskim načinom. Zadaća DOR-a je omogućiti evaluaciju ispunjavanja društvenih ciljeva. Pritom je važno odabrati varijable poduzeća koje će davati informaciju o njegovom društvenom učinku, mjeriti ih potrebnim metodama te temeljem toga oblikovati potrebne informacije koje se potom dijele s dionicima poduzeća (Ramanathan, 1976).

Dok je koncept DOR-a u svijetu poznat od 70tih godina 20. stoljeća (Mathews, 1997; Gray, 2001), u Republici Hrvatskoj on je još uvijek relativno nov. U Hrvatskoj se počeo intenzivnije spominjati tek posljednjih nekoliko godina kada se je počeo stvarati znanstveni interes za ovu problematiku (Eerma, Friedrich, Mošnja – Škare, 2012 – visoko obrazovanje; Štifanić, 2012. – srednje veliki i veliki poslovni subjekti). Razlog tome je što se tradicionalno računovodstvo usmjerava ka analizi uspješnosti poslovanja isključivo temeljem ostvarenog financijskog rezultata. Pri tome su temeljni izvor informacija financijska izvješća. DOR ima za cilj proširiti postojeći općeprihvaćeni računovodstveni sustav na način da ga dopuni informacijama koje bi govornice koliko je neko poduzeće ili institucija (privatna ili javna) društveno uspješno. Drugim riječima, DOR je informacijski sustav koji se smjestio između poduzeća (institucija) s jedne strane i društva s druge strane. Njegova svrha nadilazi isključivo financijsko izvještavanje jer pored potonjeg u obzir uzima i odgovornost prema dionicima i ciljevima društva.

Teorija društveno odgovornog računovodstva konstantno se razvijala posljednjih četrdesetak godina (Mathews, 1997; Gray, 2001). Njezina važnost posebno se ističe kod javnog sektora iz razloga što on ima ključnu ulogu u alokaciji javnih sredstava i u pružanju javnih usluga. Unatoč

tome, sam koncept društveno odgovornog računovodstva češće se je vezao uz privatni sektor i velika poduzeća.

Koncept DOR-a se u literaturi obično promatra kroz tri vremenska perioda 1971-1980, 1981-1990 te 1991-1995 (Mathews, 1997). Razlika između DOR-a i onog tradicionalnog se, prije svega, očituje u njihovom usmjerenju. DOR za razliku od tradicionalnog financijskog računovodstva u svojim financijskim izvješćima želi zadovoljiti društveni i etički aspekt poslovanja. Posebno se ističe problem odgovornosti (eng. *accountability*) pri čemu se koncept DOR-a isprepliće sa stakeholder teorijom (teorijom interesnih skupina). Potrebno je da poduzeće definira svoje dionike jer prema njima i definira svoju odgovornost (Gray i dr., 1997). Pored promatranja DOR-a kroz vremenske periode, ističe se i nekoliko pristupa ovisno o samom smjeru spomenutog koncepta. Početak koncepta DOR-a povezuje se prvenstveno s područjem računovodstva okoliša gdje se naglasak stavlja na poslovanje poduzeća usmjereno ka odgovornosti prema okolišu. Pored standardnih financijskih izvješća, poduzeća koja su implementirala ovaj vid računovodstva, sastavljaju i dodatna, nefinancijska, izvješća usmjerena izvještavanju utjecaja poduzeća na okoliš (npr. emisija štetnih plinova). Sljedeći pristup usmjeren je ka obuhvaćanju širih društvenih učinaka i koristi, a ističu se i pristupi primjenjivani isključivo u području određene djelatnosti poput zdravstva ili obrazovanja. (Eerma, Friedrich, Mošnjica – Škare, 2012).

Ramanathan (1976, p. 522) kao fundamentalni koncept DOR –a ističe tzv. društvenu transakciju. Društvena transakcija predstavlja korištenje, odnosno isporuku društvenih resursa koji utječu na interese organizacije, a koje se ne događaju na tržištu. Potpuni društveni utjecaj organizacije dobije se kada se skupno sagledava utjecaj društvenih transakcija s neto prihodima. Kako bi se utvrdio raskorak između ukupnog društvenog interesa s jedne i financijskog neto prihoda s druge strane, potrebno je utvrditi društvene troškove, društveni povrat te društveni prihod. Pritom se društveni troškovi mogu promatrati kao vrijednost negativnih, a društveni povrat kao vrijednost pozitivnih eksternalija. S druge strane društveni prihod predstavlja neto društveni doprinos organizaciji te se dobije kao zbroj tradicionalnog neto prihoda, ukupnih društvenih troškova i ukupnih društvenih povrata.

Sve se više ističe da, pored financijskih, svaki poslovni subjekt generira i mnoge nefinancijske učinke koje tradicionalni računovodstveni sustav nije u potpunosti u mogućnosti pratiti. DOR u većini slučajeva nije alternativa tradicionalnom računovodstvenom sustavu, nego dopuna

istoga. Tako, pored poznatih i priznatih financijskih izvještaja DOR iste nadopunjuje onima koji bi trebali dati informaciju o društvenoj odgovornosti, odnosno o koristima i troškovima koji nastaju poslovanjem nekog javnog ili privatnog subjekta prema okruženju u kojem djeluje. Te koristi i troškove često nije jednostavno prepoznati i mjeriti iz razloga što se one procjenjuju te su podložne subjektivizmu što uvelike otežava primjenu ovog sustava i stvara otpor pojedinaca. Unatoč tome, tijekom godina razvile su se metode njihove procjene i broj poduzeća koja objavljuju DOR izvješća je u konstantnom porastu u cijelom svijetu, prvenstveno u razvijenim zemljama Europe, SAD-u i Japanu. Taj trend je prisutan prije svega iz razloga što se očekuje da će, uvođenjem ovog vida izvješćivanja, poduzeća ostvariti višu razinu reputacije i kompetitivnu prednost (Martinuzzi, Krumay, Pisano, 2011). Pritom valja naglasiti kako veličina poduzeća ili organizacije igra važnu ulogu jer se pokazalo kako su izuzetno velika poduzeća sklonija objavljivanju društvenih informacija (Adams, Hill, Roberts, (1998), Bayoud, Kavanagh, Slaughter (2012)). Ukoliko se zaobiđu ograničenja, sustav društveno odgovornog računovodstva može biti izuzetno društveno koristan alat. Na sljedećoj shemi prikazan je knjigovodstveni sustav društveno odgovornog računovodstva.

Sustav društveno odgovornog računovodstva na poznate temelje trgovačkog i proračunskog računovodstva dodaje nove, suplementarne elemente društveno odgovornog računovodstva tako da u sebi sadrži (Eerma, Friedrich, Mošnja – Škare, 2012):

- (društveno odgovorno računovodstveni) sustav – tradicionalno računovodstvo dopunjeno suplementarnim sustavnom društveno odgovornog računovodstva
- tekuću društvenu neto korist - standardan izvještaj o dobiti i gubitku, račun dobiti i gubitka (izvještaj o poslovanju) dopunjen suplementarnim izvještajem o društvenoj uspješnosti
- ukupnu društvenu bilancu - (klasična) bilanca dopunjena suplementarnom društvenom bilancom

Društvene koristi i troškovi direktno su povezani s temeljnom funkcijom društveno odgovornog subjekta. Na taj način definirane društveno odgovorne koristi proizlaze iz baznog poslovanja i aktivnosti kojima se subjekt bavi, a društveno odgovorni troškovi daju informaciju vezanu za sklonost plaćanja za inpute. Salda stoje iza društvene imovine i društvenih obveza koji ukazuju na društvene koristi i troškove dulje od jednog obračunskog razdoblja. Računi razgraničenja dopuštaju odvajanje društvenih koristi i društvenih troškova koji ne proizlaze iz aktivnosti društveno odgovornog subjekta, u ovom slučaju, visokoobrazovne institucije. (Eerma, Friedrich, Mošnja – Škare, 2012).

Eerma, Friedrich, Mošnja – Škare (2012) predložili su i novi računski plan od 10 razreda koji bolje odgovara ovakvom tipu računovodstva, a prikazan je u tablici 13.

Tablica 13: Računski plan društveno odgovornog računovodstva

Klasifikacija

Aktiva	0 - materijalna društvena imovina, ljudski kapital
	1 - društveni novac
	2 - društvena potraživanja
Pasiva	3 - društveni vlastiti izvori, usklađenja
	4 - društvene obveze i društvena neto korist
Društvene koristi	5 - društvene koristi
Društveni troškovi	6 - društveni materijalni troškovi, troškovi osoblja
Tehnički računi	7 - obračunski, prijelazni računi
	8 - razgraničenja - računi stanja
	9 - razgraničenja - računi uspješnosti

Izvor: Eerma, D., Friedrich, P. i Mošnja – Škare, L. (2012) „Standardni okvir društveno odgovornog računovodstva – mogućnosti integracije u tradicionalni računovodstveni sustav institucija visokog obrazovanja“, *Ekonomski misao i praksa*, God XXI, br. 1

Prema računskom planu prikazanom u prethodnoj tablici, predlagane su i njegove inačice kojima bi se približio važećim propisanim računskim planovima. Društveno odgovorno računovodstvo, iako poznato već dugi niz godina, predstavlja još nedovoljno primjenjivan koncept. U novije vrijeme javljaju se autori koji ga pokušavaju implementirati u određene sustave javnog sektora s ciljem naglašavanja njihove transparentnosti i uspješnosti.

Konceptu društveno odgovornog računovodstva može se pristupiti na više načina te ga se može primjenjivati, kako u privatnom, tako i u javnom sektoru. Kod implementacije i primjene sustava DOR-a bitan je individualan pristup kojim bi se on prilagodio korisnicima kojima je namijenjen. Metode koje se koriste u jednoj djelatnosti, ne mogu se u potpunosti prilagoditi drugoj zbog različitih ciljeva, uvjeta poslovanja, opisa same djelatnosti i dr. Iz tog razloga znanstvenici su počeli razvijati koncept društveno odgovornog računovodstva primjenjiv u visokom obrazovanju.

Iako se obrazovanju često skeptično pristupa sa stajališta opravdanosti troškova i ostvarenih koristi, ipak su predlagani načini implementacije te vršene analize poput benefit – cost (B-C) analize kojom su se procjenjivale koristi i troškovi obrazovanja (Briggs, Sullins (1982), Woodhall, M. (2004), Psacharopoulos (2014)). Problem kod primjene ove analize je taj što je u obrazovanju najistaknutije investiranje u ljudski kapital. Ovakav tip investiranja donosi neekonomske koristi koje je često izuzetno teško kvantificirati. S obzirom da je po definiciji benefit-cost analiza alat kojim ekonomisti mjere ekonomske koristi određene investicije, ova analiza se isticala kao neprimjenjiva u visokom obrazovanju. Ipak, s obzirom da je utvrđeno da ulaganje u visoko obrazovanje posljedično dovodi do značajnih ekonomskih koristi, ovakav tip analiza se provodio unatoč spomenutim ograničenjima. Kod provedbe benefit-cost analize u visokom obrazovanju je, pored ekonomskih koristi i troškova, potrebno uključiti i kvantificirati i društvene koristi i troškove koje institucije visokog obrazovanja nedvojbeno imaju (Woodhall, 2004).

Novi način pristupa obrazovanju te koristima i troškovima koje ono generira doveo je do potrebe stvaranja dopune tradicionalnom računovodstvenom sustavu. Friedrich i dr. (2000) prema Erma, Friedrich, Mošnja – Škare (2012) navode kako sustav vrednovanja korištenjem B-C analize ima slabosti jer nedovoljno uzima u obzir:

- *„društvenu uspješnost fakulteta unutar godine dana*
- *cjeloviti obuhvat transakcija*
- *set tehnika za izbor i evaluaciju transakcija*
- *konvencije oko istovjetne primjene na sve involvirane institucije*
- *razgraničavanje društvene (ne)uspješnosti na pojedine institucije*
- *konvencije, u slučaju potrebne verifikacije transakcija*
- *periodični obuhvat transakcija*
- *unilateralno dimenzioniranje koristi i troškova*
- *opće i posebne postupke i klasifikacijski sustav*
- *periodično knjiženje promjena uspješnosti i stanja u financijskom računovodstvu*
- *računovodstveni sustav*
- *efikasne poveznice s drugim sustavima računovodstva “.*

Kako bi se anulirale navedene slabosti, autori smatraju kako je nužno tradicionalni računovodstveni sustav dopuniti sustavom društveno odgovornog računovodstva.

Pred visoko obrazovanje, a pogotovo ono javno, stavlja se obveza odgovornosti prema društvu koja podrazumijeva da se pored standardnih financijskih izvješća i izvješćuju svoje dionike uspješnosti svog poslovanja (Pursglove, Simpson (2007), Arnaboldi, Azzone (2004). Iako je tema društvenog izvještavanja u području visokog obrazovanja izuzetno aktualna, ipak postoji značajan deficit u istraživanjima na ovu temu. Zbog važnosti ovog problema potrebno je izvršiti veće napore kako bi se pružio značajniji doprinos ovoj tematici (Farneti, Guthrie, 2008).

Dio istraživanja u području društveno odgovornog računovodstva u Republici Hrvatskoj usmjeren je na djelatnost visokog obrazovanja. S obzirom da su visokoobrazovne institucije proračunski korisnici i sukladno tome primjenjuju proračunsko računovodstvo, sustav društveno odgovornog računovodstva u segmentu visokog obrazovanja predložen za Hrvatsku je zapravo modifikacija postojećeg korištenog računovodstvenog okvira.

Pristup B-C analize korišten je u jedinoj implementaciji društveno odgovornog računovodstva u visokom obrazovanju Republike Hrvatske. (Erma, D., Friedrich, P. i Mošnja – Škare, L., 2012). Autori su uspjeli sustav primijeniti na primjeru fakulteta koji funkcionira u sklopu sveučilišta. Na primjeru navedene institucije procijenili su društvene koristi i troškove te temeljem toga formirali dodatni izvještaj o društvenoj uspješnosti, dodatnu društvenu bilancu te su temeljem informacija iz dodatne društvene bilance i tradicionalne bilance prikazali integriranu bilancu spomenute visokoobrazovne institucije. Iako su naveli brojna ograničenja predloženog modela, on prikazuje značajan pomak na području implementacije društveno odgovornog računovodstva u institucijama javnog sektora te predstavlja smjernicu za daljnju dopunu sustava.

S obzirom da poduzeća i institucije (tu se prvenstveno misli na ona javno orijentirana) imaju za cilj zadovoljavanje javnih potreba, na što tradicionalni računovodstveni sustav nije pružao potpun odgovor po pitanju vrednovanja ostvarenja tih ciljeva i potreba, sustav društveno odgovornog računovodstva trebao bi ispuniti te nedostatke i pružiti okvir za jednostavnije i točnije vrednovanje i izvještavanje po pitanju društvene uspješnosti tih subjekata.

3. TEMELJNE ODREDNICE VISOKOG OBRAZOVANJA REPUBLIKE HRVATSKE I ZEMALJA REGIJE S POSEBNIM OSVRTOM NA VISOKOOBRAZOVNE INSTITUCIJE EKONOMSKOG USMJERENJA

Visoko obrazovanje, kako u Hrvatskoj, tako i u zemljama regije, posljednjih godina prate velike promjene. One se uglavnom odnose na prilagodbu Bolonjskom sustavu visokog obrazovanja i približavanju visokoobrazovnog sustava onome Europske unije. Cilj prilagodbe je ostvarivanje prepoznatljivosti domaćih diploma i kvalifikacija u inozemstvu i njihovo međunarodno priznavanje. Spomenutim reformama morale su se prilagoditi i visokoobrazovne ustanove ekonomskog usmjerenja koje su također imale obvezu svoje programe uskladiti s onima koje propisuje Europska unija.

U ovom dijelu doktorske disertacije govori se o ulozi obrazovanja u gospodarstvu države i društvu općenito te reformi visokog obrazovanja u Europi u funkciji stvaranja njegove kvalitete. Predstavljen je sustav visokog obrazovanja u Republici Hrvatskoj s naglaskom na visokoobrazovne institucije ekonomskog usmjerenja te sustavi visokog obrazovanja u pojedinim državama regije. Također su u ovom dijelu prikazani europski i hrvatski kvalifikacijski okviri kao sredstvo osiguravanja transparentnosti i usporedivosti kvalifikacija.

3.1. ULOGA VISOKOG OBRAZOVANJA U GOSPODARSTVU DRŽAVE I DRUŠTVU OPĆENITO

Visoko obrazovanje ima više uloga u društvu. Kao njegove osnovne funkcije mogu se istaknuti obrazovna, istraživačka te utjecaj na rast i razvoj gospodarstva i društva. Obrazovanje, a pogotovo ono visoko, ima utjecaj, kako na pojedinca, tako i na gospodarstvo općenito. Pojedinac ostvaruje koristi od obrazovanja prvenstveno kroz plaću koja je u pravilu pozitivno povezana sa stupnjem obrazovanja. Također, povrat od obrazovanja za pojedinca ukazuje na to je li pojedincu pružena dovoljna razina obrazovanja (CEGES (2007), Dearden (1998), de la Fuente, Jimeno (2005)). Povrat od obrazovanja za pojedinca ima direktan utjecaj na povrat za gospodarstvo pojedine zemlje i društvo općenito. Društveni povrati prije svega ukazuju na problematiku financiranja i daju informaciju je li financiranje optimalno (European Commission (n.d.), Dearden (1998)).


Prateći ekonomsku teoriju, pogotovo onu modernu, obrazovanje se ističe kao faktor s ključnim utjecajem na gospodarski razvoj. U prošlosti se je veća pažnja poklanjala obrazovnim institucijama niže razine (osnovna i srednja škola), dok se u novije vrijeme istraživanja usmjeravaju ka visokoobrazovnim institucijama (European Commission, n.d.). Znanstveni i tehnološki rast i razvoj, kao uostalom i gospodarski rast nisu mogući bez visokog obrazovanja. Ono omogućuje pojedincu i društvu da sudjeluju u stvaranju vrijednosti utemeljenih na novim spoznajama zbog čega se danas govori o gospodarstvu utemeljenom na znanju jer upravo znanje postaje glavni input društva. Visokim obrazovanjem stječu se specifična i specijalizirana znanja i omogućuje se ljudima da kroz procese cjeloživotnog učenja nadgrade svoja postojeća znanja i iskustva ovisno o potrebama. Upravo je kvaliteta visokog obrazovanja odraz kvalitete ljudskih resursa svake zemlje. U današnje vrijeme sve više se ističe kako se ekonomska i politička snaga neke zemlje očituje u znanju koje ona posjeduje (Toffler 1990), a konkuriranje znanjem na međunarodnom tržištu postaje sve izraženije (Polšek, 2004).

UNESCO (1996) je iznio četiri stupa obrazovanja: učenje radi znanja, učenje radi rada, učenje radi zajedničkog življenja i učenje radi postojanja. U tom izvješću se naglasak stavlja na ove specifične funkcije visokog obrazovanja:

- priprema studenata za istraživanje i podučavanje;
- omogućavanje visoko specijaliziranih predavanja prilagođenih potrebama ekonomskog i društvenog života;
- otvorenost prema svemu kako bi se omogućilo sve potrebno za provođenje cjeloživotnog učenja;
- promocija međunarodne suradnje kroz internalizaciju istraživanja, tehnologije, umrežavanja i slobodnog protoka ljudi i znanstvenih ideja.

Na sljedećoj shemi ciklički su prikazani efekti koje povećanje kvalitete obrazovanja donosi u kratkom i dugom roku.


Shema 4: Ciklički prikaz efekata povećanja kvalitete obrazovanja



Izvor: Cañas, A. J., Novak, J. D.: Why the Focus Question?, Institute for Human and Machine Cognition, 2009, dostupno na: <http://cmap.ihmc.us/docs/focusquestion.html> (7.08.2010)

Važnost znanja i obrazovanja, pogotovo onog visokog, ističe se kao temelj rasta i razvoja gospodarstva i društva općenito. Visoko obrazovanje pruža specijalizirana znanja čijom implementacijom se može dovesti do višestrukih koristi u gospodarstvu neke zemlje. Na sljedećoj shemi prikazan je proces od ulaska inputa u sustav do postizanja krajnjeg cilja s primjenom u visokom obrazovanju.

Shema 5: Visoko obrazovanje u sustavu razvoja gospodarstva



Izvor: Autorica

Svaki input treba biti korišten na način da se ostvare čim veći outputi koji trebaju biti u funkciji ostvarivanja definiranih strateških i operativnih ciljeva od strane visokoobrazovne institucije te krajnjih ciljeva koji se očituju kroz utjecaj na rast i razvoj gospodarstva i društva. Iako se radi o dugotrajnom i složenom procesu, koristi od ulaganja u njega su višestruke, kako za pojedinca, tako i za gospodarstvo neke zemlje i društvo općenito.

3.2. REFORMA VISOKOG OBRAZOVANJA U EUROPI U FUNKCIJI STVARANJA NJEGOVE KVALITETE

Posljednjih desetljeća, kao posljedica globalizacije i informatizacije, visoko obrazovanje u državama Europske unije bilo je suočeno s velikim promjenama. Promjene su se dogodile u svim njezinim članicama, a odnose se, između ostalog, na povećanje broja studenata, povećanje broja visokih učilišta, povećanje mobilnosti studenata i osoblja i dr. Početak stvaranja politike visokog obrazovanja na razini Europe datira još od 1955. kad je Europska zajednica (EZ) istaknula potrebu za stvaranjem jedinstvene visokoobrazovne politike. Šćukanec (2010) ističe tri razdoblja u nastanku visokoobrazovne politike EU. U prvom razdoblju (1957. – 1971.)

pokušala se definirati zajednička politika visokog obrazovanja EZ-e te je tražen institucionalan okvir koji bi bio adekvatan za promicanje visokog obrazovanja na istom području. Drugo razdoblje (1971 – 1984) obilježila je zajednička suradnja priznata kao zajednička visokoobrazovna politika za koju EZ može formirati određene aktivnosti te je unutar Europske komisije definiran potreban administrativni aparat. U posljednjem, trećem razdoblju (1985. – 1993.) osigurana je podrška kojom se mogu pravovaljano donositi odluke o visokom obrazovanju u EZ. 1987. godine odobren je ERASMUS program od strane Europskog vijeća što se smatra završetkom ciklusa stvaranja politike visokog obrazovanja u EZ. Spomenute promjene dovele su do potpisivanja Ugovora u Maastrichtu 1991 gdje je prvi puta definirana zajednička europska visokoobrazovna politika. Spomenute promjene vodile su visoko obrazovanje Europe do Bolonjskog procesa.

Najveće promjene visokoobrazovnih politika vežu se uz potpisivanje Bolonjske deklaracije 1999. godine i implementaciju načela koje zagovara visokoobrazovni sustav država članica EU. Bolonjsku deklaraciju potpisalo je 29 europskih ministara obrazovanja s ciljem usklađivanja i usporedivosti visokoobrazovnih sustava svojih zemalja unutar europskog visokoobrazovnog prostora. Sukladno ovom dokumentu, visokoobrazovni sustav sastoji se od tri dijela, odnosno od tri vrste studija, i to preddiplomski, diplomski i poslijediplomski doktorski studij. Svrha Bolonjske deklaracije je, prije svega, novim pravilima direktno utjecati na rast kvalitete obrazovanja i istraživanja kako bi se indirektno ostvario pozitivan utjecalo na inovacije, rast, razvoj te zadovoljenje javnog interesa. Kao temeljni problemi, zbog kojih je i donesen novi sustav mjera, navode se tradicionalni pristup učenju i nedostatak izvrsnosti (European Commission, n.d.). Promicanjem partnerstva i međunarodnom suradnjom i razmjenom između visokoobrazovnih institucija unutar EU omogućila bi se razmjena znanja i ideja te bi se na taj način pridonijelo stvaranju kvalitetne akademske i istraživačke mreže.

Također, provedene su reforme kojima je cilj bio ostvarivanje autonomije visokoobrazovnih institucija u području financiranja i same organizacije. Smatralo se da institucije samostalno mogu bolje usmjeriti svoje djelovanje s ciljem ostvarenja čim boljih outputa i samih ishoda. S druge strane, te reforme su dovele do rasta obveze visokoobrazovnih institucija u sferi planiranja i izvješćivanja te je njihov rad postao predmet obavezne neovisne vanjske procjene. Time se je željela postići transparentnost poslovanja. (European Commission, n.d.; CEGES, 2007).

Valja napomenuti kako je EU zajednica 28 heterogenih zemalja i cilj reformi je stvoriti povezanost s ciljem zajedničkog napretka. O Bolonjskom procesu i prilagodbi Hrvatske istome više riječi u sljedećem poglavlju.

3.3. VISOKO OBRAZOVANJE U REPUBLICI HRVATSKOJ S NAGLASKOM NA VISOKOOBRAZOVNE INSTITUCIJE EKONOMSKOG USMJERENJA

Visoko obrazovanje i znanost u Republici Hrvatskoj usko su povezani jer je visokoobrazovnim institucijama, pored pružanja usluga visokog obrazovanja, temeljna djelatnost bavljenje znanostima. Sustave visokog obrazovanja i znanosti u Hrvatskoj uređuje Zakon o znanstvenoj djelatnosti i visokom obrazovanju (2003). Visoko obrazovanje u Hrvatskoj doživjelo je velike promjene nakon uvođenja Bolonjskog procesa tako da danas razlikujemo tzv. Predbolonjski i Bolonjski sustav.

Visoko obrazovanje u Republici Hrvatskoj prije primjene Bolonjskog sustava

Prije 2005. godine kada se novi sustav implementirao u visoko obrazovanje Hrvatske, Predbolonjski sustav bio je koncipiran na drugačiji način i promjene su uvedene kako bi se otklonile postojeće manjkavosti u vidu nedovoljne integriranosti u europski visokoobrazovni i znanstveno istraživački prostor, slabe mobilnosti, međunarodne neusporedivosti diploma i njihovog nepriznavanja i sl.

Struktura visokog obrazovanja prije implementacije Bolonjskog procesa sastojala se od tri razine. Prva razina trajala je četiri godine i njezinim završetkom student bi dobio titulu diplomirani (dipl.). Druga razina odnosila se na znanstveni magisterij, a trajala je dvije do tri godine, a stečena titula bila je magistar znanosti (mr. sc.) čemu je slijedila najviša razina, odnosno doktorski studij čijim završetkom se postizao stupanj doktora znanosti (dr. sc.). (Šlaus, Šlaus – Kokotović, Morović, 2004)

Predbolonjskom sustavu zamjerala se niska efikasnost po pitanju dužine trajanja studija pri kojoj je studentima za završetak četverogodišnjih studija u prosjeku trebalo šest do sedam godina, a postotak studenata koji bi odustali od studija bio je na visokom nivou (Šlaus, Šlaus – Kokotović, Morović, 2004). Babić, Matković i Šošić (2006) izračunali su stopu završavanja

studija prije uvođenja Bolonjskog procesa koja je iznosila između 50 i 55% (u izračunu su uzimali prosječnih šest godina potrebnih za završetak studija). Niska stopa završavanja studija dovela je do velikih gubitaka, kako osobnih koje snosi student, tako i javnih koje generira sustav. Sustavu se također predbacivala financijska neodgovornost koja se očitovala kroz dezintegraciju sveučilišta. Ona je dovela do stvaranja prevelikog broja administrativnog osoblja te nepovezanosti i nesuradnje između fakulteta unutar sveučilišta u vidu zajedničke suradnje kroz projekte i dijeljenja nastavnika koji predaju iste predmete (Polšek, 2004).

Prelazak na novi sustav trebao je donijeti strukturne promjene na način da znanost i visoko obrazovanje djeluju u funkciji razvoja društva s naglaskom na gospodarski napredak, da se podigne kvaliteta u znanosti i visokom obrazovanju te njihova integracija u europski prostor znanosti i visokog obrazovanja te da se racionalizacijom resursa dovede do rasterećivanja proračunskih izdataka.

Visoko obrazovanje u Republici Hrvatskoj nakon primjene Bolonjskog sustava

Iako je Hrvatska Bolonjskom procesu pristupila još u svibnju 2001., njegovo uvođenje visoko obrazovanje Republike Hrvatske počelo je 2005. godine. Prva generacija studenata upisanih po Bolonjskom sustavu počela je s nastavom u akademskoj godini 2005./2006. Fokus pri provedbi Bolonjskog procesa bio je na reorganiziranju studijskih programa na sveučilišne i stručne studije pri čemu se sveučilišni razdvajaju u tri kategorije (preddiplomski, diplomski i poslijediplomski studij). Također se pažnja usmjerila i priznavanju visokoškolskih kvalifikacija ostvarenih u inozemstvu te razvoju sustava za osiguranje kvalitete (SOK). SOK je u Hrvatsku je uveden 2009. godine čime je pitanje visine ostvarene efikasnosti, efektivnosti i kvalitete postalo ključno u području visokog obrazovanja (MZOS, 2007)

Razlog nastanka i provedbe Bolonjskog procesa bila je razjedinjenost europskog prostora visokog obrazovanja. Ovaj proces trebao je međusobno približiti europske sustave visokog obrazovanja s ciljem ostvarivanja prepoznatljivih kvalifikacija na europskom prostoru te omogućiti njihovu međusobnu usporedivost. Odluka o uključivanju u zajednički sustav visokog obrazovanja nastala je 1999. godine u Bolonji, a prihvatilo ju je 29 zemalja koje su se složile u namjeri da u razdoblju od 2000. – 2010. godine provedu sve potrebne mjere kako bi stvorile zajednički usklađeni europski prostor visokog obrazovanja. Republika Hrvatska uključila se je u Bolonjski proces 2001. godine kada je potpisala Bolonjsku deklaraciju zbog čega je svoje

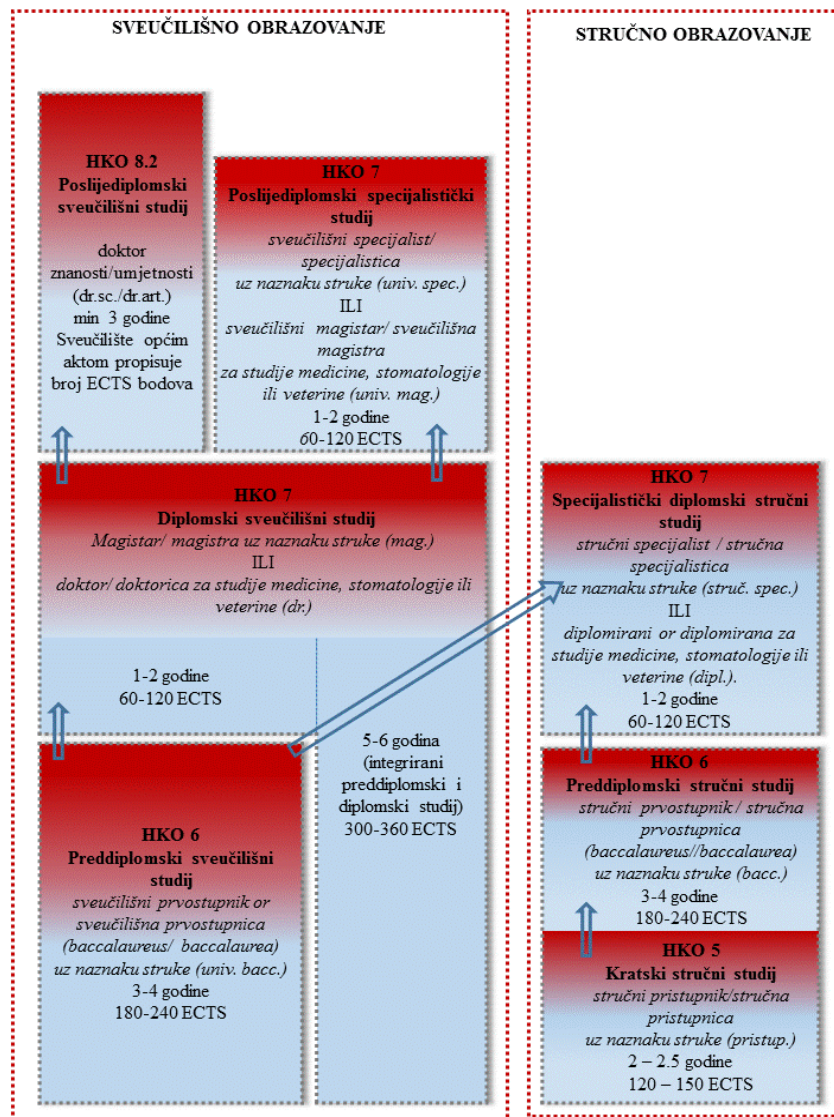
studijske programe 2005. godine uskladila s onima definiranim Bolonjskim procesom. Zakonski rok za prilagodbu visokog obrazovanja Republike Hrvatske onome koji propisuje Bolonjska deklaracija bila je 2010. godina (MZOS (2004 - 2012), Španiček (2005)).

Pitanja koja je bilo potrebno uskladiti s Bolonjskim procesom, pri čemu se posebna pažnja pridavala očuvanju i zaštiti heterogenoj europskoj kulturi i običajima, su sljedeća: (AZVO, n.d.-b)

1. sustav stupnjeva znanja formiran na razumljiv i usporediv način
2. visokoobrazovni sustav baziran na dva ciklusa,
3. sustav ECTS bodova,
4. mobilnost studenata, nastavnog i administrativnog osoblja,
5. suradnja između članica EU te garancija kvalitete,
6. zajednička dimenzija visokog obrazovanja na razini EU,
7. cjeloživotno učenje,
8. visoko obrazovanje i studenti,
9. promicanje europskog prostora visokog obrazovanja kao povoljnog prostora za studiranje.

Taj novi sustav podrazumijevao je prelazak na visokoobrazovni koncept koji se sastoji od tri ciklusa, preddiplomski u trajanju od tri godine, diplomski u trajanju od dvije godine i poslijediplomski također u trajanju od tri godine. Također su uvedeni ECTS bodovi (eng. *European Credit Transfer System*) kojima je zadaća prikazivanje realnog nastavnog opterećenja studenta, ali i pružiti informaciju koja bi trebala prije svega pružiti usporedivost diploma i ukloniti barijere kretanja studenata unutar europskog prostora visokog obrazovanja i podržati suradnju različitih zemalja unutar navedenog prostora (Španiček, 2005). Prikaz sustava visokog obrazovanja u Hrvatskoj sukladno propisima Bolonjskog procesa prikazan je sljedećom shemom.

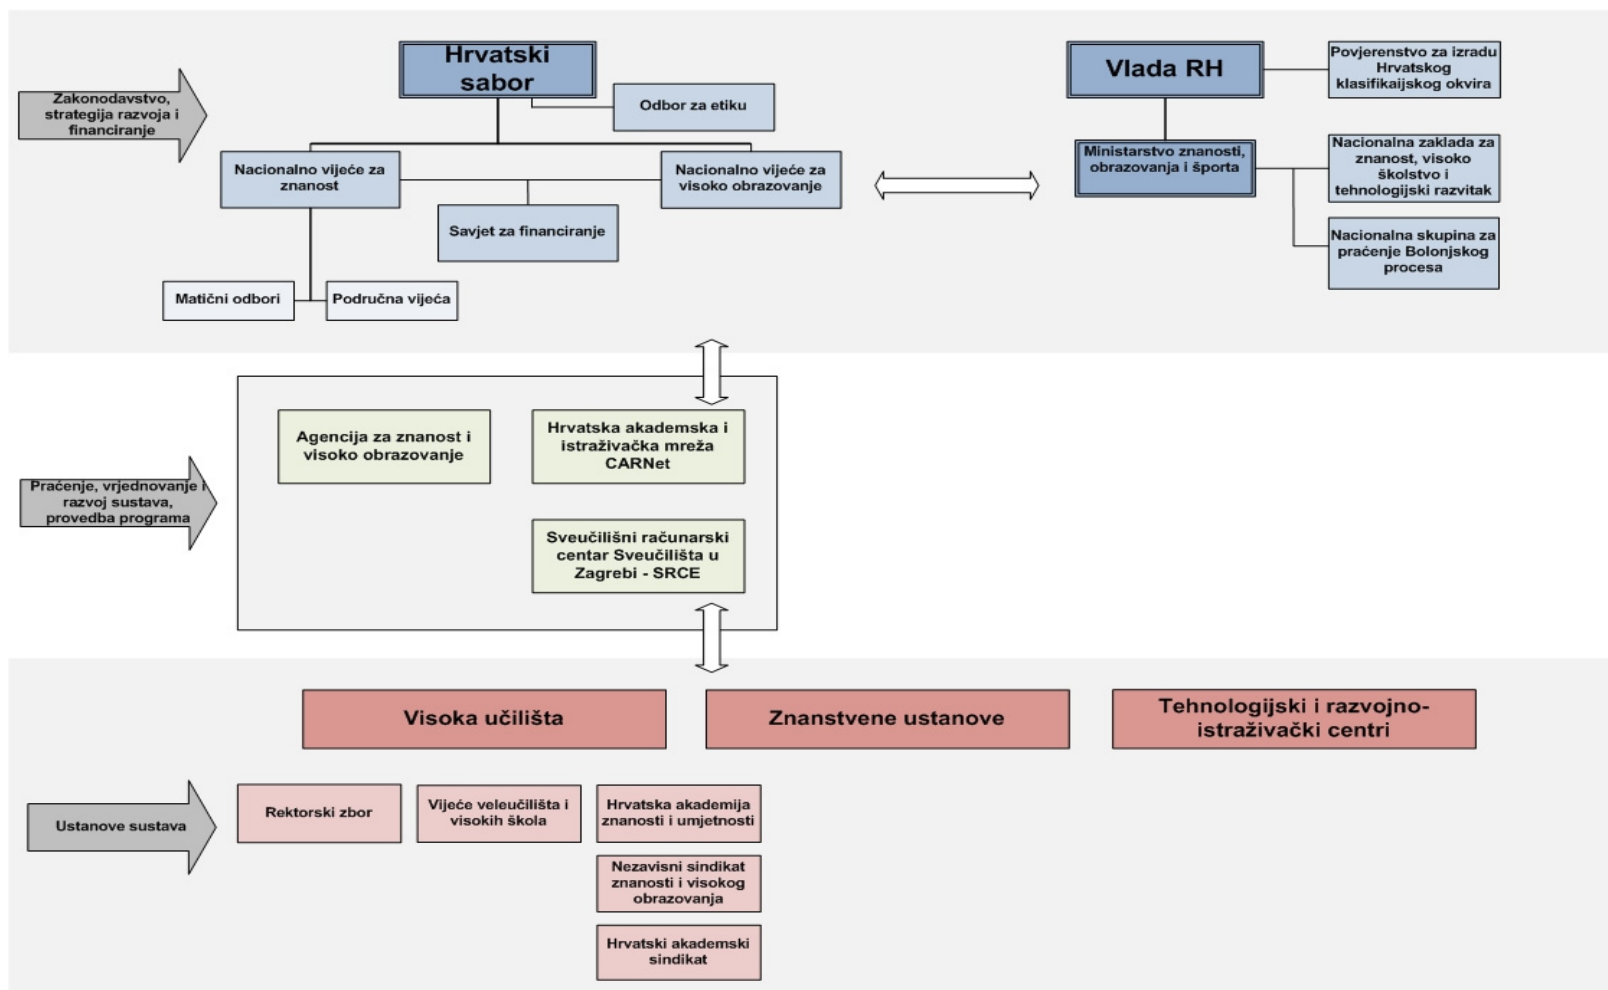
Shema 6: Prikaz sustava visokog obrazovanja u Hrvatskoj definiranih Bolonjskim procesom



Izvor: Agencija za znanost i visoko obrazovanje - AZVO (2013c). Shema studija u RH: dostupno na: <https://www.azvo.hr/hr/statistike/shema-studija-u-rh> (3.05.2015)

Kada se radi o ustroju sustava visokog obrazovanja i znanosti u Republici Hrvatskoj, on se sastoji od tri dijela, zakonodavnoga koji se prije svega odnosi na Hrvatski sabor i Vladu Hrvatske te njihova tijela koje donose odredbe. S druge strane, postoje ustanove sustava na koje se doneseni zakoni odnose te institucije koje povezuju prvi i drugi dio, a bave se praćenjem i vrednovanjem sustava i programa. Tu se posebno ističe Agencija za znanost i visoko obrazovanje koja surađuje s tijelima države s jedne strane i s institucijama visokog obrazovanja s druge strane s ciljem rasta i razvoja kvalitete u visokom obrazovanju i znanosti. Navedeno je prikazano sljedećom shemom.

Shema 7: Ustroj sustava visokog obrazovanja i znanosti u Republici Hrvatskoj



Izvor: Agencija za znanost i visoko obrazovanje – AZVO (n.d.-a): Ustroj sustava visokog obrazovanja i znanosti u Republici Hrvatskoj, dostupno na: <https://www.azvo.hr/index.php/hr/visoko-obrazovanje/ustroj-sustava-visokog-obrazovanja> (20.02.2013)

Provedeno je istraživanje o primjeni Bolonjskog procesa na hrvatskim sveučilištima pri čemu su rezultati pokazali nezadovoljstvo dionika primjenom samog sustava te su prepoznati problemi strukturalne prirode koji prate hrvatska sveučilišta još od vremena prije implementacije Bolonjskog sustava. U istraživanju su istaknuti problemi poput nepostojanja jasne vizije i misije, nedovoljne brige oko zapošljavanja asistenata i nenastavnog osoblja, nedovoljnih financijskih sredstava, nedovoljnog polaganja pažnje na znanost, slabo razvijena međunarodna suradnja te dezintegracija četiri najveća sveučilišta u Hrvatskoj (Krištof, Pisk, Radeka, 2011). Istraživanje je provedeno i na razinama samih sveučilišta, pa je Sveučilište u Rijeci temeljem pregleda svih procesa i aktivnosti provedenih na svojim sastavnicama zaključilo da je uspješno provelo Bolonjski proces koji je doveo do poboljšanja po pitanju organizacije, provođenja kvalitetnih nastavnih procesa, povećanje uspješnosti studiranja, veće transparentnosti dok se kao najveći problemi ističu, iako povećana, još uvijek nedovoljna mobilnost te slaba zapošljivost. (Sveučilište u Rijeci, 2012)

Posljednje istraživanje o Bolonjskom procesu provedeno na Sveučilistu u Zagrebu (2013) ukazuje na probleme koji prate ovaj sustav visokog obrazovanja. Rezultati istraživanja daju informaciju o slaboj mobilnosti studenata (svega 8,4% je tijekom studiranja upisalo barem jedan kolegij na drugom fakultetu, a niskih 1,5% studenata je studiralo u inozemstvu). Najčešći uzroci neupisivanja predmeta na drugim fakultetima su nezainteresiranost (35,9%), neinformiranost (35,2%) i administrativne poteškoće (16,1%), a nestudiranja u inozemstvu nedostatak financijskih sredstava (35,5%), nemogućnost dobivanja stipendije (16%), nerazmišljanje o toj mogućnosti (12,6%) te nezainteresiranost (11,5%). Kvalitetom studija su studenti najvećim dijelom uglavnom zadovoljni (48%), izrazito zadovoljno je 7,5% studenata, niti zadovoljno, niti nezadovoljno je 35,3%, uglavnom nezadovoljno je 7,9%, a izrazito nezadovoljno 1,3% studenata.

Bolonjski proces je relativno novi koncept u području visokog obrazovanja koji je doveo do velikih promjena. Radi se o dugogodišnjem, ambiciozno postavljenom projektu koji je zaživio na širokom europskom području. Iako je za cilj imao velike promjene koje su trebale dovesti do značajnih pomaka u povezivanju europskog prostora visokog obrazovanja i podizanja kvalitete studiranja, prisutne su i neke manjkavosti. Kao negativna stavka ističe se pretjerana birokratizacija, preopterećenost nastavnog osoblja, zapostavljanje znanosti te činjenica da diplome preddiplomskog studija nakon trogodišnjeg studiranja još uvijek u Hrvatskoj nisu dovoljno prepoznate na tržištu rada. U prilog sustavu također ne ide financijska kriza koja je

dovela do slabe mogućnosti zapošljavanja općenito, pa tako i osoba sa završenim visokim obrazovanjem. S druge strane, sam sustav je donio bolju transparentnost, veću mobilnost (iako u Hrvatskoj još uvijek nedovoljnu) te prepoznatljivost i priznavanje diploma i kvalifikacija na širokom europskom tržištu rada. Bolonjski proces nije završio nego se neprestano razvija. Kako bi se dobili očekivani efekti, potrebno je kontinuirano raditi na unaprjeđenju institucija visokog obrazovanja, kao i na cjelokupnom visokoobrazovnom sustavu.

Visokoobrazovne institucije ekonomskog usmjerenja u Republici Hrvatskoj

U Republici Hrvatskoj, u sklopu sveučilišta djeluje osam javnih visokoobrazovnih institucija ekonomskog usmjerenja: Ekonomski fakultet u Zagrebu, Ekonomski fakultet u Rijeci, Ekonomski fakultet u Splitu, Ekonomski fakultet u Osijeku, Fakultet ekonomije i turizma "Dr. Mijo Mirković" u Puli te Fakultet za menadžment u turizmu i ugostiteljstvu u Opatiji– djeluju kao fakulteti. U Hrvatskoj djeluju i visokoobrazovne institucije ekonomskog usmjerenja na razini odjela, a to su Odjel za ekonomiju i poslovnu ekonomiju Sveučilišta u Dubrovniku i Odjel za ekonomiju Sveučilišta u Zadru. Spomenute visokoobrazovne institucije izvode sveučilišne i stručne studije. Pored navedenih, u javne visokoobrazovne institucije ekonomskog usmjerenja mogu se uvrstiti i veleučilišta, odnosno odjeli veleučilišta koji pružaju usluge visokog ekonomskog obrazovanja. Odjeli unutar veleučilišta izvode stručne studije. Pored javnih, ulogu u visokom ekonomskom obrazovanju Republike Hrvatske imaju i privatna visoka učilišta ekonomskog usmjerenja. S jedne strane se ističu privatna veleučilišta, a s druge strane privatne visoke škole koje izvode stručne studije. U Hrvatskoj trenutno djeluje 13 javnih i 2 privatna veleučilišta od kojih nešto manje od tri četvrtine pruža usluge visokog ekonomskog obrazovanja te 27 visokih škola od kojih više od pola izvodi studije visokog ekonomskog obrazovanja (IRO, 2015).

Ekonomski fakulteti, kao i ostale visokoobrazovne institucije u Republici Hrvatskoj prošli su prilagodbu Bolonjskom procesu. Sukladno tome, nastavne aktivnosti fakulteta su se prilagodile novim pravilima. Djelatnost visokoobrazovnih institucija ekonomskog usmjerenja u Hrvatskoj sastoji se, prije svega, u pružanju usluga visokog obrazovanja iz područja društvenih znanosti, polja ekonomije te u poslovima znanstvenoistraživačkog i stručnog rada.

Tablica 14: Upisani na visoko ekonomsko obrazovanje od 2011./12. – 2013./14.

	2011./2012.	2012./2013.	2013./2014.
Broj studenata, polje ekonomija	53.875	47.091	42.750
Udio upisanih u polje ekonomija u ukupnom broju upisanih	27,3%	25%	23,9%
Upisani na ekonomske i fakultete (Zagreb, Split, Rijeka i Osijek) i Fakultet za menadžment u turizmu i ugostiteljstvu u Opatiji	32.066	26.450	23.032
Udio upisanih na ekonomske fakultete u ukupno upisanima	16,2%	14,04%	12,89%

Izvor: Agencija za znanost i visoko obrazovanje – AZVO (n.d.-c). Broj studenata po poljima od akademske godine 2008/09 do 2012/13, dostupno na: <https://www.azvo.hr/hr/statistike/1122-broj-studenata-po-poljima-od-akademske-godine-2008-09-do-2012-13> (11.07.2015); Agencija za znanost i visoko obrazovanje – AZVO (n.d.-d). Broj studenata na visokim učilištima od 2008/09 do 2013/14 godine, dostupno na: <https://www.azvo.hr/hr/statistike/broj-studenata-po-raznim-kriterijima/44-statistike/689-broj-studenata-na-visokim-uilitima-za-0910-i-1011-godinu> (11.07.2015)

Iz prethodne tablice vidljiva je brojnost visokoobrazovnih institucija ekonomskog usmjerenja. Od svih studenata upisanih na visoka učilišta u Hrvatskoj, u ak. god. 2011./12. bilo ih je 27,3% upisano u polje ekonomija, u ak. god. 2012./13. 25%, dok ih je u ak. god. 2013./14. bilo upisano 23,9%. Iako je u tri promatrane godine izražen trend opadanja spomenutog udjela sukladno zahtjevima Ministarstva, on je ipak je još uvijek dominantan i iznimno značajan. Ukoliko bi promatrali isključivo četiri najveća ekonomska fakulteta u Hrvatskoj i Fakultet za menadžment u turizmu i ugostiteljstvu u Opatiji, vidljiv je isti trend pada upisanih studenata. Promatrani fakulteti ubrajaju se u najbrojnije fakultete, odnosno radi se o fakultetima na kojima studira najveći broj studenata. U Hrvatskoj je u ak. god. 2011./2012. na promatranim fakultetima studiralo 32.066 studenta, što čini 16,2% od ukupnog broja studenata upisanih spomenute akademske godine. U ak. god. 2012./2013. udio upisanih na spomenute fakultete smanjio se na 14,04%, dok je u 2013./2014. iznosio 12,89%. Zbog navedenog razloga oni imaju izuzetno važnu ulogu u sustavu visokog obrazovanja Hrvatske. Ekonomski fakulteti i Fakultet za menadžment u turizmu i ugostiteljstvu specifični su i po tome što imaju visok udio vlastitih

prihoda u ukupnim prihodima (nerijetko prelazi 50%) što je u suprotnosti od tradicionalnog modela financiranja.

Financiranje javnih ekonomskih fakulteta i Fakulteta za menadžment u turizmu i ugostiteljstvu u Republici Hrvatskoj

Financiranje predstavlja važan segment svake visokoobrazovne institucije, pa tako i visokoobrazovnih institucija ekonomskog usmjerenja. Unatoč tome što je 2006. godina bila određena kao krajnji rok primjene financiranja temeljem programskih ugovora s ministarstvom, zbog već spomenutih problema, s primjenom se krenulo kasnije. Ekonomski fakulteti su 2013. godine počeli prelaziti na novi sustav financiranja. Ovaj sustav odnosi se isključivo na sredstva dobivena od strane ministarstva.

U ovom dijelu izvršena je usporedna analiza strukture prihoda i rashoda temeljem koje je utvrđena razina financijske neovisnosti 4 javna ekonomska fakulteta i Fakulteta za menadžment u turizmu i ugostiteljstvu.

Visoka učilišta u Hrvatskoj se otprilike financiraju s 70% javnih i 30% privatnih sredstava (Bajo, n.d.). Specifičnost ekonomskih fakulteta u Hrvatskoj je u tome što im je udio vlastitih prihoda u ukupnim prihodima izuzetno visok i često prelazi 50%. S obzirom da se i u Europi i u Hrvatskoj ističe važnost rasta udjela privatnih u odnosu na javna sredstva financiranja, u tom pogledu ekonomski fakulteti predstavljaju primjer ostalim visokoobrazovnim institucijama.

U nastavku je provedena usporedna analiza veličine i strukture javnih i komercijalnih prihoda, za četiri javna ekonomska fakulteta i za Fakultet za menadžment u turizmu i ugostiteljstvu u Opatiji (EF 1 – EF 5). U Tablici 15 prikazana je veličina i struktura prihoda za promatrane fakultete.

Tablica 15: Prikaz strukture prihoda javnih ekonomskih fakulteta i Fakulteta za menadžment u turizmu i ugostiteljstvu u Opatiji od 2009. - 2012.

	EF1				EF2				EF3				EF4				EF5			
	2009	2010	2011	2012	2009	2010	2011	2012	2009	2010	2011	2012	2009	2010	2011	2012	2009	2010	2011	2012
Prihodi iz proračuna	47,11	46,19	48,43	50,76	38,56	47,16	52,22	50,81	46,7	46,67	50,29	51,8	40,8	44,61	50,02	53,03	46,99	52,68	44,59	42,67
Vlastiti prihodi	52,89	53,81	51,57	49,24	61,44	52,84	47,78	49,19	53,3	53,33	49,71	48,2	59,2	55,39	49,08	46,97	53,01	47,32	55,41	57,33

Izvor: Izradila autorica prema: Ministarstvo financija Republike Hrvatske (MFIN) (2013) – Temeljni financijski izvještaji javnih visokih učilišta u periodu od 2009. – 2012.

Specifičnost fakulteta ekonomskog usmjerenja izražena je, između ostaloga i u vrlo visokom udjelu vlastitih prihoda u ukupnim prihodima. U svim promatranim institucijama iz prethodne tablice oni se kreću oko 50% i nerijetko prelaze taj udio. Na većini institucija (EF1-EF4) zabilježen je pad tog udjela, prije svega zbog smanjenja vlastitih prihoda na što je utjecala gospodarska kriza i smanjenje broja studenata na koje su fakulteti bili primorani uslijed odredbe MZOS-a i AZVO-a. Pod pojmom vlastitih prihoda podrazumijevaju se prihodi od poslovanja te prihodi od prodaje nefinancijske imovine.

Pored strukture prihoda bitno je izvršiti i analizu strukture rashoda izabranih fakulteta koja je prikazana na sljedećoj tablici.

Tablica 16: Prikaz strukture rashoda javnih ekonomskih fakulteta i Fakulteta za menadžment u turizmu i ugostiteljstvu u Opatiji od 2009. - 2012.

	EF1				EF2				EF3				EF4				EF5			
	2009	2010	2011	2012	2009	2010	2011	2012	2009	2010	2011	2012	2009	2010	2011	2012	2009	2010	2011	2012
Rashodi za zaposlene	76,26	79,04	80,26	76,76	57,58	65,7	71,33	76,73	68,4	70,06	69,07	74,34	64,67	64,67	62,18	61,67	65,82	66,35	61,35	59,06
Rashodi za nabavu nefinancijske imovine	1,64	1,39	1,58	0,88	4,44	4,39	4,96	2,33	0,92	1,3	1,16	1,53	3,26	3,26	36,5	35,7	32,02	30,06	35,88	37
Materijalni i ostali rashodi	22,1	19,57	18,16	22,36	37,98	29,91	23,71	20,94	30,7	28,64	29,77	24,13	32,07	32,07	1,32	2,63	2,16	3,59	2,77	3,94

Izvor: Izradila autorica prema: Ministarstvo financija Republike Hrvatske (MFIN) (2013) – Temeljni financijski izvještaji javnih visokih učilišta u periodu od 2009. – 2012.

Na svim EF najviši udio u ukupnim rashodima sadržavaju rashodi za zaposlene koji se na promatranim institucijama u 2012. godini kreću od 59,06% do 76,76%, nakon čega slijede materijalni rashodi. Ostale vrste rashoda vrlo su malo zastupljene u ukupnim rashodima.

Valja napomenuti kako su podaci preuzeti iz financijskih izvještaja javnih ekonomskih fakulteta u Hrvatskoj i Fakulteta za menadžment u turizmu i ugostiteljstvu s obzirom da i taj fakultet pruža visoko ekonomsko obrazovanje (Fakultet ekonomije i turizma "Dr. Mijo Mirković" iz Pule ima status fakulteta od 2013) tako da on nije uključen u analizu. Financijski izvještaji od 2008. - 2010. godine izrađeni su temeljem Računskog plana iz Pravilnika o proračunskom računovodstvu i računskom planu (NN, br. 27/05 i 127/07), a financijski izvještaji za 2011. i 2012. temeljem Računskog plana iz Pravilnika o proračunskom računovodstvu i računskom planu (NN, br. 114/10 i 31/11) koji je i dalje na snazi.

3.4. VISOKO OBRAZOVANJE U DRŽAVAMA REGIJE

Visoko obrazovanje na visokoobrazovnim institucijama ekonomskog usmjerenja u državama regije uvelike je slično onome koje se provodi u Hrvatskoj. Razlog tome je prihvaćanje Bolonjske deklaracije i prilagođavanje visokoobrazovnog sustava onome koji ona nalaže. Unatoč brojnim sličnostima, svaka zemlja ima svoje posebnosti. Kao i u RH, institucije ekonomskog obrazovanja i u državama regije imaju važnu ulogu i predstavljaju važnu sastavnicu sustava visokog obrazovanja. Obrazovanje koje ove institucije pružaju može se podijeliti na dvije temeljne skupine, a to je stručno i sveučilišno. S obzirom da su u istraživanje u sklopu doktorske disertacije uključene visokoobrazovne institucije ekonomskog usmjerenja Slovenije i Bosne i Hercegovine, u nastavku su kratko predstavljeni njihovi sustavi obrazovanja. Također je predstavljen i visokoobrazovni sustav Srbije kao još jedne zemlje regije.

Slovenija

Prije prelaska na bolonjski način studiranja, od 1994. godine Slovenija je razlikovala dodiplomske i poslijediplomske programe. Dodiplomski programi sastojali su se od stručnih studija (3-4 godine) i sveučilišnih studija (4-6 godina). Poslijediplomski studiji su pak razlikovali specijalistički studij (1-2 godine), znanstveni magistarski studij (2 godine) i doktorski studij (4 godine ili 2 godine za studente koji su završili znanstveni magisterij). Potpisivanjem Bolonjske deklaracije, Slovenija je 2004. godine uvela novu strukturu studija. Ova struktura je podrazumijevala sustav od tri ciklusa – preddiplomski, diplomski i poslijediplomski. Prvi ciklus podrazumijevao je stručne i sveučilišne programe u trajanju od 3 – 4 godine (180-240 ECTS). Drugi ciklus podrazumijeva magistarske programe u trajanju od 1 – 2 godine (60 – 120 ECZS), dok posljednji, treći ciklus, podrazumijeva doktorske studije u trajanju od 3 godine (180 ECTS). Posljednja generacija studenata koji ne studiraju po bolonjskom sustavu upisana je ak. god. 2008./2009 dok su prvi novi programi usklađeni s bolonjskom deklaracijom startali akademske godine 2005./2006. Sukladno navedenom, vidljivo je kako je do 2008./2009. Akademske godine Slovenija nudila i predbolonjske i bolonjske programe dok su se od 2009./2010. mogli upisati isključivo bolonjski programi (MIZŠ, 2011).

U Sloveniji djeluje nekoliko različitih tipova visokoobrazovnih institucija: sveučilišta, fakulteti, umjetničke akademije i samostalni visokoškolski zavodi. Oni mogu biti osnovani od strane države, Parlamenta ili od domaćih ili stranih organizacija ili pojedinaca. Pritom osnovane institucije prije nego započnu s radom moraju udovoljiti zahtjevima koje propisuje zakon. U Sloveniji djeluje Nacionalna agencija Republike Slovenije za kakovost v visokem školstvu (NAKVIS), pandan hrvatskoj Agenciji za znanost i visoko obrazovanje. I ova agencija vodi se ESG standardima pri osiguranju usporedive razine kvalitete između slovenskog i europskog visokog obrazovanja (MIZŠ, 2011).

Znanstvena istraživanja su usko vezana uz sustav visokog obrazovanja Slovenije. U Nacionalnom programu visokog obrazovanja od 2011 – 2020 visoko obrazovanja ističe se kao prioritet Slovenije, pogotovo u trenucima kada je suočena s financijskom krizom. Također se ističe i integracija visokog obrazovanja i znanosti kao ključa napretka (MIZŠ, 2011).

Bosna i Hercegovina

Visoko obrazovanje Bosne i Hercegovine smatra se jednim od najkompleksnijih sustava visokog obrazovanja na području zapadnog Balkana zbog podjele na dva entiteta unutar zemlje, s jedne strane na Republiku Srpsku i s druge strane na Federaciju Bosne i Hercegovine koja se unutar sebe sastoji od deset kantona. Pored navedenih entiteta, ističe se i Brčko District kao posebna administrativna jedinica. Pritom je specifično za BiH da svaka od spomenutih 13 administrativnih jedinica samostalno provodi zakone u visokom obrazovanju koje pak funkcionira unutar pravnog okvira visokog obrazovanja BiH koji se odnosi na cjelokupnu zemlju (Branković, Branković, 2013).

BiH je pristupila bolonjskom procesu 2003. godine te su sve promjene obrazovnog sustava išle u smjeru usklađivanja sa njegovim zahtjevima. Ovo se prije svega odnosi na restrukturiranje sustava visokog obrazovanja na način da se zasniva na sustavu ECTS bodova te da se sastoji od tri ciklusa (jednaka kao i kod RH i Slovenije), da razvije mehanizme za osiguravanje kvalitete, promiče mobilnost i učini diplome međusobno usporedivima. Unatoč naporima za usklađivanje sustava sukladno načelima Bolonjske deklaracije, postoje pojedini studijski programi koji nisu prihvatili ECTS sustav (Branković, Branković, 2013).

Agencija za razvoj visokog obrazovanja i osiguranje kvaliteta zadužena je za postavljanje standarda i kriterija za akreditaciju visokoobrazovnih institucija bazirajući se na načelima ESG standarda s ciljem osiguranja kvalitete u visokom obrazovanju (Branković, Branković, 2013).

Kao i u Hrvatskoj, rastući trend broja visokoobrazovnih institucija kao i broja studenata zabilježen je i u dvije promatrane zemlje. Unatoč razlikama visokoobrazovnih sustava promatranih zemalja, može se uočiti tendencija približavanja europskim normama kojima se omogućuje njihova međusobna usporedivost.

Srbija

Prije provedbe Bolonjskog procesa, dodiplomski studij u Srbiji trajao je od 4 do 6 godina. U praksi je taj period u prosjeku trajao znatno duže. Tako je prosječno trajanje studija od četiri godine iznosilo 6,76 godina, studija od pet godina 7,51 godinu, dok je studij u trajanju od šest godina u prosjeku završavao za 7,62 godine. Odstupanje između predviđenog i realnog trajanja studija ukazivalo je na visoku neefikasnost visokoobrazovnog sustava što je išlo u prilog njegovoj reformi. Također, stopa odustajanja bila je izrazito visoka i iznosila je 45%. Pored navedenog, bio je prisutan jaz između znanosti i privrede zbog nepovjerenja privrede prema znanstvenim radnicima. Uvođenjem Bolonjskog procesa željelo se je stvoriti jasne okvire kojima bi se poboljšala efikasnost studiranja, povećala kvaliteta studenata te kako bi se zadovoljili zahtjevi gospodarstva (Jarić, Vukasović (2009), Veinović (2010)).

Bolonjski proces u Srbiji je uveden 2003. godine. Kao i kod Slovenije, Hrvatske i BiH, on podrazumijeva studiranje bazirano na tri ciklusa, povećanje mobilnosti studenata i osoblja te prepoznatljivost diploma na Europskom prostoru visokog obrazovanja. Kako bi svoj pravni okvir prilagodila reformama u visokom obrazovanju, donesen je Zakon o visokom obrazovanju koji je usvojen 2005.

Djelatnost visokog obrazovanja u Srbiji provodi se putem sveučilišta, fakulteta, akademije stručnih studija, visoke škole te visoke škole stručnih studija (mpn, 2015).

3.5. EUROPSKI I HRVATSKI KVALIFIKACIJSKI OKVIR KAO SREDSTVO OSIGURAVANJA TRANSPARENTNOSTI I USPOREDNOSTI KVALIFIKACIJA

Trend povezivanja Europe doveo je u pitanje način prepoznavanja i usporedbe kvalifikacija radnika iz različitih zemalja. Pod pojmom kvalifikacija, smatra se skup kompetencija, odnosno ishoda učenja, određenih razina, obujma, profila i kvalitete koja se dokazuje službenom ispravom koju izdaje nadležna ustanova (MZOS, 2013b). Kako bi se one mogle prepoznati i postati jednoobrazne, ustrojen je Europski kvalifikacijski okvir (EKO). On služi kao instrument uspostave razine kvalifikacija na način da djeluje kako bi se prepoznale kvalifikacije između nacionalnih kvalifikacijskih okvira (NKO). EKO – om nastoje se obuhvatiti ne samo formalni oblici učenja, što je zadaća Bolonjskog procesa, već i razni obrazovni podsustavi i drugi načini stjecanja kompetencija. Uloga NKO slična je onoj EKO, ali se ovdje stečene kvalifikacije prepoznaju na razini određene zemlje (Dželalija, 2007). EKO za cilj ima promicati mobilnost građana između zemalja i poticati cjeloživotno učenje.


Sve razine kvalifikacija koje je moguće steći kroz opće, strukovno i akademsko obrazovanje i osposobljavanje (uključujući i cjeloživotno učenje) predmet su EKO. U prvi plan stavljaju se ishodi učenja koji se prikazuju kroz znanja, vještine, samostalnost i odgovornost koje pojedinac posjeduje.

NKO uvodi skup kriterija kojima povezuje i koordinira sve dijelove nacionalnog kvalifikacijskog sustava. Primjer NKO je Hrvatski kvalifikacijski okvir (HKO) čija je zadaća da pruži osnovu za jasnije razumijevanje, bolju prohodnost, stjecanje i višu kvalitetu kvalifikacija. Pritom treba uvažavati interese tržišta rada, pojedinca i društva u cjelini. Kao opći cilj HKO – a navodi se osiguravanje povezanosti i koordinacije svih dijelova hrvatskog kvalifikacijskog sustava (uključuje se i tržište rada) (MZOS (2013b), Beljo Lučić i dr. (2009)).

HKO ima više specifičnih ciljeva od kojih su neki (MZOS (2013b), Beljo Lučić i dr. (2009)): održiva zaposlenost, dostupnost sustava obrazovanja, jedinstveni sustav osiguravanja i unaprjeđenja kvalitete postojećih i novih kvalifikacija, izgradnja sustava vrednovanja neformalnog i informalnog učenja, osiguravanje gospodarskog rasta kojemu je temelj znanstveno—tehnološki razvoj, jačanje konkurentnosti gospodarstva Republike Hrvatske koja se temelji na ljudskim potencijalima i dr.

EKO trebao bi služiti kao poveznica između različitih NKO. Na sljedećoj shemi dan je prikaz uloge EKO kao instrumenta povezivanja HKO i NKO neke druge zemlje. Vidljivo je kako se uspostavljanjem kvalifikacijskih okvira djeluje na transparentnost kvalifikacija i njihovo lakše razumijevanje izvan okvira jedne zemlje.

Shema 8: Uloga Europskog kvalifikacijskog okvira kao instrumenta uspostave kvalifikacija između različitih zemalja: primjer Republike Hrvatske (Hrvatski kvalifikacijski okvir)



Izvor: Beljo Lučić i dr. 2009, Hrvatski kvalifikacijski okvir - Uvod u kvalifikacije, Vlada Republike Hrvatske, Ministarstvo znanosti, obrazovanja i športa, Zagreb, Dželalija, M. (ur.)

Iz sheme je vidljivo kako se (MZOS, 2013b):

- 1. razina HKO-a povezuje s 1. razinom EKO-a;
- 2. razina HKO-a povezuje s 2. razinom EKO-a;
- 3. razina HKO-a povezuje s 3. razinom EKO-a;
- 4.1. razina HKO-a povezuje s 4. razinom EKO-a;
- 4.2. razina HKO-a povezuje s 4. razinom EKO-a;
- 5. razina HKO-a povezuje s 5. razinom EKO-a;
- 6. razina HKO-a povezuje s 6. razinom EKO-a;

- 7. razina HKO-a povezuje s 7. razinom EKO-a;
- 8.1. razina HKO-a povezuje se kao djelomična razina s 8. razinom EKO-a
- 8.2. razina HKO-a povezuje s 8. razinom EKO-a.

HKO se, kao i EKO, sastoji od 8 razina od kojih su neke podijeljene na više podrazina. Njihov prikaz zajedno sa razinom trajanja svake od njih i ECTS bodovima koji se ostvaruju na pojedinim razinama prikazani su na sljedećoj shemi. Potrebno je napomenuti da je više i visoko obrazovanje obuhvaćeno od pete razine prema zadnjoj, osmoj razini.

Shema 9: Hrvatski kvalifikacijski okvir

Razine	Vrste studija - obrazovnih programa		Trajanje	ECTS bodovi
	Sveučilišni studij	Stručni studij		
8	8.2	Poslijediplomski doktorski studij	3 i više godina	
	8.1	Dosadašnji poslijediplomski magistarski studij	2 godine	
7	7.2	Poslijediplomski specijalistički studij	1-2 godine	60-120
	7.1	Diplomski studij	Specijalistički diplomski stručni studiji	1-2 godine 60-120
6	Preddiplomski studij		Stručni studiji	3-4 godine 180-240
5			Stručni studiji	Više od 2, a manje od 3 godine 120-179
4	4.3	Majstor specijalist		Do 1 godine
	4.2	4-godišnje obrazovanje za određeno zanimanje, s položenom državnom maturom		4 godine
	4.1	3-godišnje obrazovanje za određeno zanimanje, s položenom završnim ispitom		3 godine
3	Program za stjecanje niže stručne spreme		1-2 godine	
2	Osmogodišnje obrazovanje + stručna osposobljenost za jednostavne poslove		1-6 mjeseci	
1	Osmogodišnja škola		8 godina	

Izvor: Vlada Republike Hrvatske (n.d.). Polazne osnove Hrvatskoga kvalifikacijskog okvira, dostupno na: www.vlada.hr/hr/content/download/22392/file/243%20-%2012.pdf (5.02.2013)

Svrha kvalifikacijskih okvira je, između ostalog, osigurati sustav osiguranja kvalitete na način da se ponuda kvalifikacijskih struktura usuglasi s ponudama tržišta rada. Cilj je osigurati provedbu sustava na svim razinama obrazovanja temeljem ishoda učenja. Obrazovne, a među njima i visokoobrazovne ustanove mogu sustavno osiguravati kvalitetu na način da održavaju i trajno unapređuju dogovorene standarde svojih proizvoda i usluga. Standardi imaju važnu ulogu jer se njima omogućuje transparentnost i usporedivost kvalifikacija te se jasnije može dobiti i uvid u razinu kvalitete svake obrazovne institucije. Unutar HKO osiguranje kvalitete podrazumijeva osiguranje kvalitete u odnosu na: (MZOS, 2012a)

- uključivanje dionika i međunarodnih stručnjaka pri izradi i provedbi HKO
- svrsishodnost kvalifikacija
- kurikulum (niz planiranih postupaka koje za cilj imaju stjecanja kompetencija pojedinca)
- kriterije i postupke za ocjenjivanje
- kriterije i postupke kod dodjele kvalifikacija

HKO trebao bi doprinijeti svima onima koji su ostvarili kvalifikacije u obrazovnim institucijama u Republici Hrvatskoj te se predviđa da bi njegovo korištenje trebalo dovesti do povećanja kvalitete. Razlog tome je taj što će se njegovom primjenom omogućiti povezivanje s drugim kvalifikacijskim okvirima unutar Europe na način da će se kvalifikacije moći lakše uspoređivati čime će se omogućiti veća konkurencija na europskom tržištu rada. Usporedivost kvalifikacija bi građanima Republike Hrvatske trebala omogućiti da lakše studiraju i rade u inozemstvu jer će im kvalifikacije biti u potpunosti prihvaćene. (MZOS, 2012a)

4. KONCEPT EFIKASNOSTI I EFEKTIVNOSTI KAO ODREDNICA KVALITETE VISOKOG OBRAZOVANJA

U profitnom sektoru detaljno su definirani i kvantificirani pokazatelji efektivnog poslovanja. U javnome sektoru vladaju drugačija pravila i, za razliku od privatnog sektora, ovdje visina profita ne definira uspješno (efektivno) poslovanje od onog manje uspješnog. Javni sektor karakterizira situacija gdje količina i kvaliteta isporučenih usluga u odnosu na plan određuje one uspješne. Pritom je potrebno voditi računa i o efikasnosti poslovanja koja nalaže da se s raspoloživim inputima ostvare čim viši outputi. Problem vezan za efikasnost i efektivnost poslovanja javnog sektora je taj da se sredstva iz proračuna raspoređuju njihovim korisnicima temeljem ciljeva koje oni ispunjavaju, a ne temeljem ostvarene efikasnosti ili efektivnosti poslovanja. To je često više politička nego poslovna odluka. Ipak, na proračunske korisnike vrši se sve veći pritisak od strane poreznih obveznika koji očekuju rezultate koji nastaju uporabom njihovih sredstava te čim transparentnije informacije o korištenju istih.

Neki autori (Vašiček i dr. (2011), Budimir (2006)) navode da se sustavi pokazatelja u javnome sektoru mogu uspostaviti kao izvedenica onih u privatnom sektoru te na taj način postati mjera ocjene ekonomičnosti, uspješnosti i djelotvornosti institucija javnog sektora. Kao mjera vrednovanja uspješnosti u javnom sektoru navodi se i primjena bilance postignuća (eng. *balanced scorecarda* (BSC)) kao karte pokazatelja koja mjeri uspješnost poslovanja korištenjem računovodstvenih i neračunovodstvenih informacija. Mjere su izvedene iz strategije institucije, a njihova svrha je stvoriti okvir pomoću kojega bi se moglo vršiti planiranje svih poslovnih aktivnosti te mjeriti ostvarenu uspješnost uspoređujući ostvarenja s temeljnim njezinim čimbenicima. Model je razvijen početkom devedesetih godina dvadesetog stoljeća, a razvili su ga Kaplan i Norton (1992). Svrha modela bila je pružiti okvir za strateško upravljanje i mjerenje uspješnosti.

S obzirom da su u literaturi dostupne razne definicije kvalitete, u ovom radu ona će se definirati kroz rezultate efikasnosti i efektivnosti, odnosno kroz dobivene outpute i ishode. Za visokoobrazovne institucije ključno je definirati željene ishode i postignuti ih na efikasan način.

Vrednovanje efikasnosti i efektivnosti visokog obrazovanja nije jednostavno jer se na te institucije ne mogu direktno primijeniti definirana pravila koja vladaju u profitnom sektoru.

Istraživači su ovim problemima pristupali iz različitih kutova gledišta i korištenjem različitih metoda vrednovanja, ali kompleksnost poslovanja ovih institucija i sve strože mjere koje se stavljaju pred njihovo poslovanje otkrivaju brojne neriješene probleme i predstavljaju daljnji izazov istraživačima diljem svijeta.

4.1. DEFINIRANJE KVALITETE VISOKOG OBRAZOVANJA

U segmentu visokog obrazovanja, prihvaćanje osiguranja kvalitete i njezine kontrole bilo je dugo vremena zanemarivano i površno obrađivano. Zadnjih dvadesetak godina kvaliteti visokog obrazovanja počela se pridavati veća pozornost. Ona se ističe kao temelj stvaranja Europskog prostora visokog obrazovanja. Osiguranje kvalitete u visokom obrazovanju evoluirajući je koncept koji ne obuhvaća više samo nastavne aktivnosti nego i ostale aktivnosti proizašle iz drugih oblika djelovanja visokoobrazovnih institucija. S obzirom da su visokoobrazovne institucije dinamične i višedimenzionalne ustanove koje u svojem poslovanju objedinjavaju različite procese, potrebno je njihovu kvalitetu sagledavati sa strane svakog pojedinog procesa i aktivnosti kako bi se dobila cjelovita slika. Naglasak je stavljen na važnost razvoja kriterija i metodologije za osiguranje kvalitete koja bi bila zajednička svim zemljama koje su potpisale Bolonjsku deklaraciju.

Osiguranje kvalitete postalo je ključna tema kako u svijetu, tako i u Hrvatskoj. Razlog tome je veliki porast broja studenata i visokoobrazovnih institucija zbog čega je sustavno održavanje kvalitete postalo izazov i obveza današnjeg društva. Kvaliteta visokoobrazovnog sustava ima direktan utjecaj na kvalitetu ljudskog kapitala što neposredno utječe na gospodarski rast i razvoj.

Evalucije visokoobrazovnih institucija od strane državnih organizacija ili samostalnih istraživača provode se s ciljem osiguranja određene razine kvalitete. Osiguranje kvalitete visokoobrazovnih institucija obuhvaća sve procese i aktivnosti koje provodi određena institucija, a koje imaju za cilj očuvanje općeprihvaćenih standarda i očekivanja društva. Ovaj koncept podrazumijeva i konstantni rad visokoobrazovnih institucija na unapređivanju vlastitih poslovnih procesa i ishoda (Beljo Lučić i dr. (2009), Zakon o osiguranju kvalitete u znanosti i visokom obrazovanju (2009)). Procjena razine kvalitete objedinjava sve mjere efikasnosti i efektivnosti definirane od strane ljudi koji predstavljaju akademsku zajednicu dok se pod kontrolom kvalitete visokog obrazovanja smatra proces provjere pri kojem se utvrđuje

zadovoljavaju li proizvodi i usluge visokoobrazovnih institucija minimum postavljenih standarda (Mishra, 2007).

Visokoobrazovne institucije sve su više orijentirane ka što kvalitetnijem provođenju svojih procesa i aktivnosti. Mishra (2007) navodi nekoliko razloga za to:

- Konkurencija – u današnje vrijeme kada je prisutna globalizacija, konkurencija između obrazovnih institucija sve je izraženija. Visokoobrazovne institucije se međusobno bore za studente i financijska sredstva.
- Zadovoljstvo korisnika – studenti, roditelji i svi ostali vezani za obrazovni sustav zahtijevaju na dobivanju što veće vrijednosti za svoj potrošeni novac i vrijeme. Zato se programi koji se provode na institucijama visokog obrazovanja moraju kontinuirano prilagođavati potrebama tržišta rada.
- Održavanje standarda – visokoobrazovne institucije trebaju voditi brigu o postavljanju standarda i njihovom kontinuiranom održavanju. Postizanje i održavanje standarda je usko vezano uz održavanje kvalitete.
- Odgovornost – svaka visokoobrazovna institucija je odgovorna svojim ulagačima (privatnim ili javnim). Oni očekuju visoku razinu kvalitete za svoj novac.
- Povećanje motivacije zaposlenika – zaposlenici će imati veću motivaciju izvršavati svoje dužnosti kada postoji briga za povećanje kvalitete visokoobrazovne institucije.
- Kredibilitet, prestiž i status – interes za povećanje kvalitete dovest će do profiliranja visokoobrazovne institucije te će to imati utjecaj na rast kredibiliteta pojedinaca i institucije te će ona kao takva uživati viši status.
- Slika u društvu i prepoznatljivost – kvalitetne visokoobrazovne institucije imaju veću mogućnost privlačenja boljih studenata i financijskih sredstava.

Osiguranje kvalitete visokog obrazovanja postalo je jedno od temeljnih pitanja Europske unije. 1999. godine potpisana je Bolonjska deklaracija kojom se planiralo stvoriti tzv. Europski prostor visokog obrazovanja (eng. *European Higher Education Area*).

Europska udruga sveučilišta (eng. *European University Association - EUA*) je u suradnji s Europskom komisijom 2002. pokrenula projekt (eng. *Quality Culture Project*) u kome je sudjelovalo 134 europska sveučilišta. Zbog velikih raznolikosti po pitanju pristupa vrednovanja kvalitete visokoobrazovnih institucija, izrađen je čitav niz studija i prijedloga sa svrhom

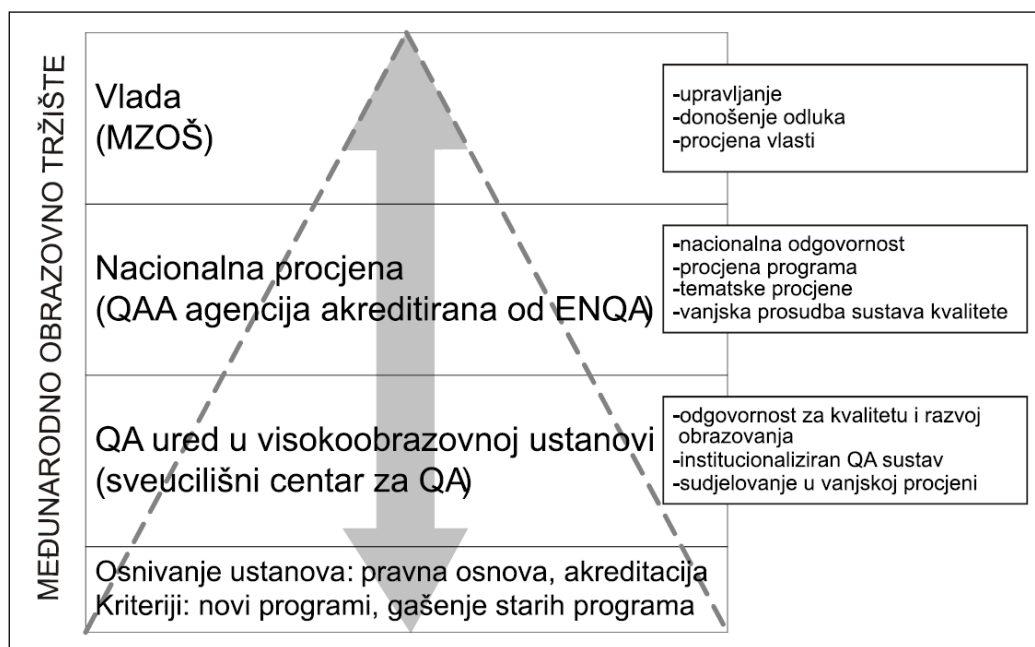
utvrđivanja europskih standarda. (EUA, n.d.). EUA za postizanje kvalitete ističe važnost institucionalne autonomije te uloge vlada prema kojoj bi one trebale pasivno nadgledati visoko obrazovanje, a ne regulirati ga. (Dolček – Alduk, Sigmund, Lončar – Vicković, 2008).

Uzevši Bolonjsku deklaraciju kao bazu, 2000. godine osnovano je Europsko udruženje za osiguranje kvalitete visokog obrazovanja (eng. *European Association for Quality Assurance in Higher Education* – ENQA). ENQA (n.d.) trenutno ima u nadležnosti 40 agencija u 23 zemlje Europskog prostora visokog obrazovanja i 49 agencija iz 28 zemalja svijeta odgovornih za održavanje kvalitete u svojim matičnim zemljama. Ona im kroz svoje publikacije donosi informacije o razvoju evaluacije visokog obrazovanja, organizira radionice, pruža savjetodavnu ulogu i sl.

U Berlinskom priopćenju od 19. rujna 2003, europski ministri obrazovanja zemalja koje su potpisale Bolonjsku deklaraciju apelirali su na ENQA-u da putem svojih članica i u suradnji s organizacijama EUA, EURASHE (eng. *European Association of Institutions in Higher Education*) i ESU (eng. *The European Students Union*, tada ESIB) (tzv. grupa E4), razvije "dogovoreni skup standarda, postupaka i smjernica za osiguravanje kvalitete", tzv. Standarde i smjernice za osiguravanje kvalitete u Europskom prostoru visokog obrazovanja (eng. *Standards and Guidelines for Quality Assurance in the European Higher Education Area* - ESG standardi). Tijekom postupka stvaranja i oblikovanja ESG standarda, ENQA-i je naloženo da u obzir također uzme i ekspertize ostalih udruga i organizacija koje imaju zaduženje osiguravati kvalitetu (ENQA, 2009). Europski ministri obrazovanja su u svibnju 2005. u Bergenu usvojili ESG standarde. Radi se o dokumentu koji je postavljen vrlo općenito s razlogom da ga mogu primjenjivati sve visokoobrazovne institucije na području Europskog prostora visokog obrazovanja. Njegova zadaća je da pomogne visokoobrazovnim institucijama i agencijama za osiguranje kvalitete da, korištenjem njega kao predložka, naprave svoje standarde i smjernice uvažavajući pritom različite nacionalne sustave visokog obrazovanja i samostalnost institucija i agencija unutar različitih nacionalnih sustava. U Berlinskom priopćenju također je odlučeno i da se uspostavi Europski registar agencija za osiguranje kvalitete (eng. *European register of quality assurance agencies*) koji je 2006. uspostavio Europski parlament te je odredio minimalne uvjete koje moraju zadovoljiti agencije kako bi bile upisane u njega (ENQA, n.d.). Pored navedenoga definirani su i osnovni elementi koje trebaju imati nacionalni sustavi za osiguranje kvalitete (BFUG Working Group on Stocktaking, 2005): unutarnje vrednovanje, vanjska procjena, uključenost studenata, objavljivanje rezultata i međunarodna participacija.

Ovi događaji doveli su do stvaranja dva nova koncepta: autonomna sveučilišta i autonomne agencije za osiguranje kvalitete. Također, u Europskom prostoru visokog obrazovanja dolazi do mnoštva dogovora koji dovode do standardiziranja procesa i stvaranja zajedničkih kriterija (Dolček – Alduk, Sigmund, Lončar – Vicković, 2008). Ti procesi i kriteriji postali su baza stvaranja standardiziranog međunarodnog obrazovnog tržišta koje povezuje nacionalne sustave osiguranja kvalitete visokog obrazovanja država. Nacionalni sustav osiguranja kvalitete visokog obrazovanja prikazan je na shemi 12 na primjeru Republike Hrvatske.

Shema 10: Nacionalni sustav osiguranja kvalitete visokog obrazovanja u sklopu međunarodnog obrazovnog tržišta



QA – osiguranje kvalitete (eng. *quality assurance*)

QAA – agencija za osiguranje kvalitete (eng. *quality assurance agency*)

Izvor: Dolček – Alduk, Z., Sigmund, V., Lončar – Vicković, S. (2008): Osiguranje kvalitete visokog obrazovanja u europskom obrazovnom prostoru, Tehnički vjesnik, 15(1):39-44


Većina europskih država intenzivno radi na razvijanju unutarnjih i vanjskih mehanizama za osiguranje kvalitete, a izvještaji o samovrednovanju su njihova poveznica. Unatoč intenzivnom razvoju unutarnjih sustava kvalitete europskih zemalja, problem je u tome da su oni uglavnom usmjereni ka osiguranju kvalitete nastave. Na razvoju osiguranja kvalitete istraživanja radi vrlo mali broj institucija (manje od jedne trećine) dok manje od jedne šestine institucija uključuju

administraciju u procjenu kvalitete. (Nacionalna zaklada za znanost, visoko školstvo i tehnologijski razvoj Republike Hrvatske, 2007)

U Republici Hrvatskoj postoji izrazita povezanost između visokog obrazovanja i znanosti. Primarnu odgovornost osiguranja kvalitete imaju visoka učilišta i znanstvene organizacije dok se odgovornost za procese osiguravanja kvalitete u Republici Hrvatskoj veže uz Nacionalno vijeće za visoko obrazovanje (NVVO), Nacionalno vijeće za znanost, Rektorski zbor, Studentski zbor i Vijeće veleučilišta i visokih škola te Agenciju za znanost i visoko obrazovanje (AZVO, 2013b).

Sustav osiguranja kvalitete u Republici Hrvatskoj prikazan je sljedećom shemom:

Shema 11: Sustav osiguranja kvalitete u Republici Hrvatskoj




Izvor: Lazibat, T., Sutić, I., Jurčević, M. (2009): Quality Management System at The Faculty of Economics and Business, 31st Annual EAIR Forum in Vilnius, Lithuania

Zakon o visokim učilištima (1993) djelomično je obuhvaćao vanjske mehanizme za osiguranje kvalitete. U njemu je sadržana odredba prema kojoj NVVO (tada Nacionalno vijeće za visoku naobrazbu), stručno tijelo koje se brine za kvalitetu cijelog sustava visokog obrazovanja Republike Hrvatske, treba u roku od jedne godine od imenovanja (početak 1994.) provesti postupak vrednovanja postojećih visokih učilišta na način koji je zakonom utvrđen te predložiti Saboru Republike Hrvatske donošenje odluke o programu preobrazbe visokih učilišta. Taj rok je produžavan u nekoliko navrata zbog nedostatka ljudskih i financijskih resursa. Implementacija bolonjskog procesa u Republici Hrvatskoj dovela je do zastoja u daljnjem vrednovanju visokih učilišta. Zakon je predviđao periodično vrednovanje svakih pet godina, ali NVVO ne samo da nije to uspjelo provesti, nego neka visoka učilišta nisu niti bila podvrgnuta procesu vanjskog vrednovanja čak niti nakon 2004. godine. Deset godina nakon donošenja Zakon o visokim učilištima, 2003. godine donesen je Zakon o znanstvenoj djelatnosti i visokom obrazovanju koji je Zakon o visokim učilištima iz 1993 uzeo kao bazu i nadgradio ga većinom komponentama vezanim za organizacijsko – stručne postupke vrednovanja visokih učilišta i programa koje provode. Zakon je omogućio i uključivanje službi za osiguranje kvalitete u proces vrednovanja programa i institucija. Donošenje ovoga zakona često se smatra početkom razvoja sustava za održavanje i unapređenje kvalitete u Republici Hrvatskoj (Nacionalna zaklada za znanost, visoko školstvo i tehnologijski razvoj Republike Hrvatske, 2007).

Vanjska kontrola kvalitete visokoobrazovnih institucija postala je obavezna u mnogim zemljama. Zakon o znanstvenoj djelatnosti i visokom obrazovanju (2003) naložio je osnivanje Agencije za znanost i visoko obrazovanje (AZVO) koja je osnovana krajem 2004. godine, a započela je s radom u ožujku 2005. AZVO se brine o osiguranju kvalitete u znanosti i visokom obrazovanju u Republici Hrvatskoj, njezina organizacijska struktura prikazana je na shemi. Agencija se sastoji od tri tijela, Upravnog vijeća, Ravnatelja i Akreditacijskog savjeta koji u svom sastavu zastupaju predstavnike svih dionika unutar sustava znanosti i visokog obrazovanja radi postizanja čim veće transparentnosti. Odluke vezane za poslovanje te nadzor nad radom Agencije vrši Upravno vijeće, Ravnatelj ima ulogu predstavljanja Agencije i ima odgovornost za njezino cjelokupno poslovanje dok Akreditacijski savjet ima obvezu donošenja dokumenata potrebnih za obavljanje vanjskog vrednovanja, donosi odluke oko imenovanja stručnih povjerenstava te iskazuje mišljenje o izvršenim vanjskim vrednovanjima temeljem priloženih završnih izvješća (AZVO, 2010).

Shema 12: Organizacijska struktura Agencije za znanost i visoko obrazovanje



Izvor: Agencija za znanost i visoko obrazovanje – AZVO (2010): Priručnik kvalitete Agencije za znanost i visoko obrazovanje, Zagreb, Dostupno na: http://static.fpz.hr/kvaliteta/files/AZVO_Prirucnik_kvalitete_final.pdf pregledano: (13.03.2013)

Osiguranje kvalitete uređeno je Zakonom o osiguravanju kvalitete u znanosti i visokom obrazovanju (2009) te se njegove odredbe primjenjuju na „javna i privatna visoka učilišta, javne znanstvene institute i druge znanstvene organizacije kojima je osnivač Republika Hrvatska te privatne znanstvene institute i druge pravne osobe upisane u Upisnik znanstvenih organizacija“. AZVO samostalno obavlja poslove utvrđene Zakonom pritom uvažavajući međunarodnu praksu i zakone, a nadzor nad zakonitošću njezina rada provodi Ministarstvo znanosti, obrazovanja i športa. Može se reći kako se AZVO brine o vanjskom sustavu osiguranja i unapređenja kvalitete temeljem nacionalnih, europskih i međunarodnih standarda dok je osiguranje i unapređenje unutarnjeg sustava kvalitete u nadležnosti svakog pojedinog visokog učilišta kojeg ona uređuje svojim općim aktom. Svaki predmet vrednovan od strane visokog učilišta odgovoran je za efikasnost i efektivnost aktivnosti vezanih za obrazovanje i znanost.

Cilj postupka vrednovanja je odrediti razinu kvalitete, efikasnosti i svrsishodnosti predmeta vrednovanja i studijskih programa. Zakon o osiguravanju kvalitete u znanosti i visokom obrazovanju (2009) navodi sljedeće postupke vanjskog i unutarnjeg vrednovanja:

- Inicijalna akreditacija – spada u postupak vanjskog vrednovanja, a njome se vrednuju novi predmeti ili studijski programi. Ukoliko se utvrdi da zadovoljavaju određene odredbe i standarde, izdaje se akreditacijska preporuka sa svrhom izdavanja dopusnice visokim učilištima ili znanstvenim organizacijama za obavljanje djelatnosti.
- Reakreditacija - dio je postupka vanjskog vrednovanja gdje AZVO temeljem stručnog i neovisnog mišljenja donosi ocjenu i preporuke za poboljšanje već postojećih predmeta i studijskih programa. Time se potvrđuje ispunjenje uvjeta potrebno za daljnje obavljanje djelatnosti visokih učilišta ili znanstvenih organizacija.
- Tematsko vrednovanje – provodi se od strane AZVO – a na temelju njezinog akreditacijskog savjeta. Provodi se temeljem obrazloženog prijedloga ministra, predmeta vrednovanja ili studentskog zbora visokog učilišta.
- Vanjska neovisna periodična prosudba unutarnjeg sustava osiguravanja kvalitete – neovisna prosudba AZVO – a o razvijenosti i učinkovitosti provođenja unutarnjeg sustava za osiguranje kvalitete. AZVO na temelju prosudbe daje preporuke u obliku izvješća i izdaje certifikat.

Osiguranje kvalitete visokoobrazovne institucije odgovornost je svih zaposlenika počevši s top menadžmentom. Potrebno je redovito provoditi samoevaluacije kako bi se dobio uvid u cjelokupno poslovanje. Također je važna usporedba sa sličnim visokoobrazovnim institucijama (eng. *benchmarking*) da bi se dobio realan prikaz položaja promatrane visokoobrazovne institucije. Primjere dobre prakse (oni koji posluju bolje) treba detaljno proučiti i pokušati implementirati neke njihove ideje kako bi poboljšali svoju poziciju. Pritom treba biti oprezan jer imitiranje tuđih postupaka ne mora uvijek dati iste željene učinke. Ipak, one najefikasnije i najefektivnije treba uzeti za primjer i pokušati ih dostići.

4.2. DEFINIRANJE EFIKASNOSTI U VISOKOM OBRAZOVANJU

Efikasnost je pojam koji govori o tome s koliko se je inputa (ulaznih jedinica, sredstava) ostvario određeni output (izlazni rezultat). Cilj je sa što manje ulaznih elemenata dobiti čim više izlaznih, odnosno optimizirati korištenje inputa. Optimalne vrijednosti za inpute i outpute su zapravo vrijednosti koje poduzeće, institucija ili država može ostvariti iskorištavajući svoj

puni potencijal. Ukoliko je subjekt to uspio, on se smatra efikasnim. Mjerenje efikasnosti u javnom sektoru često se smatra složenijim zbog nepostojanja dobrih kao kriterija vrednovanja poslovanja subjekta. Kod institucija visokog obrazovanja problem je što one koriste mnoge inpute kako bi proizvele (isporučile) mnoge outpute, a njihovi outputi su često kvalitativne prirode što dodatno otežava postupak vrednovanja.

Webster, Kennedy i Johnson (1998) istaknuli su postojanje velikog broja različitih tipova efikasnosti i njihovu međusobnu povezanost (shema 10). Ekonomska efikasnost, kao fundamentalni ekonomski problem predstavlja vršnu razinu efikasnosti. Došenović Bonča (n.d.) je navela dvije različite vrste ekonomske efikasnosti, a to su, s jedne strane proizvodna efikasnost koja se ostvaruje kada proizvođači proizvode dobra i usluge na način da koriste najbolju moguću tehnologiju definiranu funkcijom proizvodnje te efikasnost potrošnje koja se ostvaruje kada potrošači maksimiziraju svoju funkciju korisnosti, a polazi od preferencije u njihovim odlukama o potrošnji. U analizi efikasnosti, kako u radovima koji se bave tematikom vrednovanja efikasnosti visokog obrazovanja, tako i u ovoj doktorskoj disertaciji, izučava se isključivo proizvodna efikasnost, odnosno ona koja proizlazi iz određenog proizvodnog procesa. Zbog toga će se u ovoj doktorskoj disertaciji pod pojmom ekonomske efikasnosti smatrati isključivo proizvodna efikasnost. Funkcija proizvodnje, odnosno proizvodna funkcija pritom podrazumijeva specificiranje outputa nekog proizvodnog procesa za svaku kombinaciju inputa (Ramanathan, 2003).


Ekonomska efikasnost može biti statička i dinamička. Ona se pretežito promatra sa statičkog aspekta, ali sadrži komponente dinamičke efikasnosti. Pod time se isključivo misli na uspjeh ekonomskih analitičara da predvide i menadžera da prilagode poslovanje određenog subjekta potencijalnim prijetnjama ili mogućnostima vezanim za samu proizvodnju i distribuciju dobara ili usluga te promjenama želja i potreba potrošača (Webster, Kennedy i Johnson, 1998). Dinamička efikasnost dobila je na značaju jer se tijekom vremena u subjektima poput poduzeća ili institucija događaju promjene te je na analitičarima da utvrde ne samo koje promjene su se dogodile, već i koliko njih je uzrokovano tehnološkim napretkom, a koliko posebnim inicijativama uz postojeću tehnologiju.

Ekonomska efikasnost se dijeli se na alokativnu i tehničku. Alokativna efikasnost postoji kod optimalne raspodjele dobara i usluga i mjeri se na posredan način stavljanjem u odnos troškovne i tehničke efikasnosti. Tehnička efikasnost često se spominje u analizi omeđivanja podataka, a

definirana je od strane Nunamakera (1985) kao mjera ili mogućnost neke jedinice ili donosioca odluke da proizvede maksimalnu količinu outputa s raspoloživom količinom inputa ili da proizvede postojeću količinu outputa, a da pritom koristi minimalnu količinu inputa te na taj način izbjegne bilo kakve gubitke. U AOMP obično se mjeri upravo tehnička efikasnost.

Tehnička efikasnost se pak sastoji od efikasnosti obujma i čiste tehničke efikasnosti (Tehnička efikasnost (TE)= Efikasnost obujma (EO) * Čista tehnička efikasnost (ČTE)). Rezultat CCR modela (objašnjenje u poglavlju 5.2.1.) naziva se globalna TE, dok se rezultat BCC modela (objašnjenje u poglavlju 5.2.1.) naziva lokalna ČTE. Pritom se u ČTE očituje neefikasno djelovanje, a u EO loši uvjeti djelovanja (Cooper, Seiford, i Tone, 2007). Donosioc odluke može biti tehnički efikasan, ali da mu je proizvodnja premala ili prevelika. EO predstavlja sposobnost poslovnog subjekta da izbjegne bilo kakve gubitke na način da iskoristi znanje o ekonomiji obujma na način da prilagodi svoju veličinu onoj optimalnoj, odnosno da uvijek proizvodi na razini obujma koji omogućuje najveću produktivnost. Taj koncept je prvi predložio Banker (1984).

Shema 13: Rastavljanje efikasnosti na temeljne vrste



Izvor: Webster, R., Kennedy, S., Johnson, L. (1998): Comparing Techniques for Measuring the Efficiency and Productivity of Australian Private Hospitals, Working paper in Econometrics and Applied Statistics, Australian Bureau of Statistics, No. 98/3

Ekonomska efikasnost, kao predmet proučavanja ovog rada, može biti izražena u jednoj od tri forme ovisno o tome na koji način se prikazuje najbolja proizvodna tehnologija (Došenović Bonča, n.d.):

- a) troškovna efikasnost (eng. *cost efficiency* - CE) (određena proizvodnja outputa se proizvodi s najmanjim troškovima)

Na taj način definirana CE može se mjeriti kao odnos između minimalnih i stvarnih troškova (Bogetoft, Otto, 2011):

$$CE = \frac{\omega x^*}{\omega x} \quad (4.1)$$

Pri tome se troškovi ωx danog plana proizvodnje (x, y) mogu evaluirati putem kombinacije troškova outputa (c, y) pri čemu je $c = \omega x$. Optimalna kombinacija minimalnih troškova x^* dobije se rješavanjem problema minimizacije troškova (Bogetoft, Otto, 2011):

$$\min \omega'x \quad \text{je dio skupa } (x', y) \in T \quad (4.1)$$

čije je rješenje u točki x^* .

TE je također jednaka odnosu troškova \tilde{x} i troškova x iz razloga što su ta dva vektora proporcionalna. Stoga TE možemo definirati kao:

$$TE = \frac{\omega \tilde{x}}{\omega x} \quad (4.2)$$

Ukoliko usporedimo troškove x^* i \tilde{x} , njihova razlika su troškovi nastali zbog odabira tehnički efikasnog plana \tilde{x} umjesto jeftinije kombinacije inputa x^* . Ta razlika predstavlja alokativni problem te se alokativna efikasnost dobije kao (Bogetoft, Otto, 2011):

$$AE = \frac{\omega x^*}{\omega \tilde{x}} \quad (4.3)$$

Ako je AE manja od 1 znači da se moglo bolje rasporediti sredstva prema jeftinijoj kombinaciji inputa.

CE, TE i AE su međusobno povezane na način da je (Bogetoft, Otto, 2011):

$$CE = AE \cdot TE \quad (4.4)$$

Drugim riječima, subjekt je troškovno efikasan jedino ako je u mogućnosti izabrati ispravnu kombinaciju inputa koje potom koristi na tehnički efikasan način.

- b) prihodovna efikasnost (eng. *revenue efficiency* – RE) (proizvodnja takve kombinacije outputa koja osigurava maksimalne moguće prihode)

Ovako definirana RE ovisi o cijenama outputa $p \in \mathbb{R}_+^m$ te se može pisati u obliku sljedećeg izraza (Bogetoft, Otto, 2011):

$$RE = \frac{py^*}{py} \quad (4.5)$$

gdje y predstavlja stvarni, a y^* optimalni output. Za ostvarenje RE potrebno je odabrati najbolju kombinaciju outputa u odnosu na prihode, odnosno mora se ostvariti output TE i output AE (Bogetoft, Otto, 2011).

- c) profitna efikasnost (eng. *profit efficiency* – PE) (proizvodnja upravo one količine outputa koja maksimizira profit)

Ukoliko su poznate cijene inputa ω i outputa p moguće je utvrditi sposobnost subjekta da ostvari profit. Pritom se PE definira kao (Bogetoft, Otto, 2011):

$$PE = \frac{py - \omega x}{py^* - \omega x^*} \quad (4.6)$$

gdje (x, y) predstavljaju promatrani proizvodni plan, a (x^*, y^*) profitno maksimizirajući proizvodni plan čije je rješenje (Bogetoft, Otto, 2011):

$$\max py' - \omega x' \quad \text{je dio skupa } (x', y') \in T \quad (4.7)$$


Ostvarivanje PE niže od 1 znači da nisu iskorištene sve mogućnosti za ostvarivanje profita.

Govoreći o efikasnosti, spominje se još i društvena efikasnost kojom se maksimizira društveno blagostanje, a između ostaloga, treba u obzir uzeti i eksternalije. Ova vrsta efikasnosti posebnu važnost igra u povezivanju poduzeća s državom gdje država treba inzistirati na ostvarivanju pozitivnih eksternalija, a negativne minimizirati. Društvena neefikasnost se manifestira kada su koristi nastale od proizvodnje nadmašene negativnim efektima za društvo koje one se njome generiraju. Ova vrsta efikasnosti najčešće se spominje u vidu očuvanja prirode te se koncept društveno odgovornog računovodstva upravo razvio na njezinim temeljima.

4.3. DEFINIRANJE EFEKTIVNOSTI U VISOKOM OBRAZOVANJU

Kako bi se čim točnije definirala efektivnost, bitno je naglasiti njezinu različitost od efikasnosti jer se ti pojmovi često ne razlikuju i koriste se kao sinonimi. Upravljanje efikasnošću ima ključnu ulogu u javnom sektoru jer se time omogućuje efikasna i racionalna alokaciju javnih resursa (ljudskih, financijskih, tehničkih i ostalih koje javne institucije koriste kako bi ostvarile svoju misiju i ciljeve poslovanja) i njihovo transparentnije trošenje. Efektivnost se, s druge strane, postiže na način da se pri vrednovanju uvažavaju dugoročni, strateški ciljevi određenog subjekta čime se osigurava njegova održivost te se ova mjera zato često smatra i važnijom u upravljanju javnim sektorom. Ona predstavlja mogućnost postizanja postavljenih ciljeva i postavlja poslovanje svakog subjekta u odnos sa planovima i ciljevima koje si je postavio. Unatoč tome, bitno je naglasiti kako su te dvije mjere (efikasnost i efektivnost), iako imaju različita značenja, međusobno komplementarne. Efikasnost predstavlja mjeru na kratki rok, dok je efektivnost mjera usmjerena na dugoročnu izvedbu poduzeća ili institucije. Nužan preduvjet ostvarivanja efektivnosti je ostvarivanje efikasnosti iz razdoblja u razdoblje. S druge strane, efikasno poslovanje može biti jedino ono koje je usmjereno ostvarivanju dugoročnih ciljeva.

Shema 14: Povezanost efikasnosti i efektivnosti



Izvor: Autorica

Efikasnost se još definira sintagmom „raditi stvari na ispravan način“, a efektivnost „raditi ispravne stvari“. Uspješne organizacije su jedino one koje su i efikasne i efektivne (Drucker, P., 2006) što se može prikazati matricom na sljedećoj tablici.

Tablica 17: Matrica efikasnosti i efektivnosti

		EFIKASNOST	
		NISKA	VISOKA
EFEKTIVNOST	VISOKA	Prave stvari se rade na krivi način	Prave stvari se rade na pravi način
	NISKA	Krive stvari se rade na pravi način	Krive stvari se rade na krivi način


Izvor: Autor prema: Drucker, P. (2006)

Jedina ispravna opcija koja omogućuje održivo poslovanje na kratak i dugi rok je ona gdje postoje i visoka efikasnost i visoka efektivnost, a koja podrazumijeva „raditi prave stvari na pravi način“.

U novijim istraživanjima veći naglasak se stavlja na efikasnost kao mjeru usporedbe poslovanja različitih subjekata nego na efektivnost. Razlog tome je u nedostatku spoznaja o preferencijama samog subjekta. Nedostatak čvrstih informacija o vezi između inputa i outputa zamjenjuje se pretpostavkama tako da se efikasnost pojedinih subjekata pozicionira u odnosu na granicu efikasnog poslovanja (Bogetoft, Otto, 2011)

Na grafikonu 7 je vidljivo kako je granica efektivnosti T postavljena na višoj razini od granice efikasnosti T*. Granica efektivnosti predstavlja potpuno zadovoljavanje preferencija U ostvarujući na taj način ideal poslovanja. S obzirom da preferencije U najčešće nisu u potpunosti jasne, kao relevantna mjera usporedbe poslovanja subjekta uzima se granica efikasnosti. Razlog tome je pristupanje problemu s pozicije stvarnih ostvarenja gdje se granica formira temeljem poznatih podataka o najboljoj praksi.

Grafikon 7: Međuodnos efikasnosti i efektivnosti na primjeru visokog obrazovanja



Izvor: Autor prama: Bogetoft, Otto (2011)

Efektivnost se može matematički izraziti na sljedeći način (Bogetoft, Otto, 2011):

$$Efektivnost = \frac{U(A)}{\max_{y \in T} U(y)} = \frac{U(A)}{U(Idealan)} \quad (4.8)$$

Pritom je pitanje koliko je moguće proporcionalno proširiti A s proizvodnom kombinacijom T . Na taj način dobiva se projekcija točke A u točku $\tilde{F}A$. Pritom \tilde{F} predstavlja apsolutnu output efikasnost prema Farrellu (Bogetoft, Otto, 2011):

$$\tilde{F} = \max\{f \mid fA \in T\} \quad (4.9)$$

S obzirom da T u realnom okruženju nije poznat, pretpostavlja se T^* i kreira se granica tzv. relativne efikasnosti jer se subjekti pozicioniraju jedni u odnosu na druge. Sukladno tome, točka A se projicira u točku FA gdje F predstavlja relativnu output efikasnost prema Farrellu (Bogetoft, Otto, 2011):

$$\tilde{F} = \max\{f \mid fA \in T^*\} \quad (4.10)$$

U visokom obrazovanju unaprjeđenje efektivnosti bi se odnosilo na uvođenje mjera kojima bi se istovremeno optimiziralo korištenje resursa sa svrhom ostvarenja definiranih ciljeva. Pritom se polazi od zadovoljavanja interesa svih zainteresiranih skupina (npr. studenata, roditelja, države, agencija za evaluaciju i dr.). Kod definiranja ciljeva potrebno je krenuti od misije, vizije

i strategije promatrane organizacije. Cilj svake visokoobrazovne institucije trebao bi biti usmjeren da s čim manje, ciljano i planski, usmjerenih sredstava (osoblje, financijska, materijalna i nematerijalna sredstva) doprinese ostvarivanju svojih dugoročnih ciljeva poput unaprjeđenja kvalitete nastavnog rada, postizanja znanstvene prepoznatljivosti institucije kroz kvalitetna istraživanja objavljena u vrhunskim časopisima, ostvarivanje suradnje s gospodarskom zajednicom kroz zajednički realizirane projekte i sl. S obzirom da visokoobrazovne institucije imaju više dimenzija djelovanja, kvaliteta kao funkcija ostvarivanja efikasnosti i efektivnosti se ne može promatrati samo kroz jednu kategoriju, nego se trebaju uvažiti sva relevantna područja njihovog djelovanja.

5. METODOLOŠKI OKVIR ZA MODELIRANJE VREDNOVANJA VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA


Tijekom godina razvio se čitav niz metoda vrednovanja visokog obrazovanja. U privatnom sektoru proces njihovog razvoja i same implementacije bio je jednostavniji nego u javnom jer je tamo temeljna odrednica u vrednovanju efikasnosti i efektivnosti visina ostvarenog profita. S obzirom da javni sektor ima funkciju zadovoljavanja javnih potreba, situacija postaje kompliciranija jer su, pored kvantitativnih, prisutni i mnogi kvalitativni učinci koji podliježu subjektivnoj procjeni te ih nije jednostavno izmjeriti. Unatoč tome, veliki broj istraživača bavio se ovom problematikom i predložio čitav niz metoda mjerenja efikasnosti i efektivnosti. Potpisivanjem Bolonjske deklaracije visoko obrazovanje prošlo je čitav niz reforma među kojima se kao jedan od ključnih ciljeva izdvaja rast razine kvalitete visokoobrazovnih institucija zemalja koje su pristupile provođenju Bolonjskog procesa čime je ovo područje postalo dodatni izazov istraživačima. Interes za ovu problematiku prisutan je i u zemljama izvan Europe između kojih se Australija i Kanada, pored Velike Britanije ističu kao zemlje u kojima sustav osiguranja kvalitete funkcionira na visokoj razini. Najveći broj istraživanja koja se tiču postizanja visoke razine kvalitete te vrednovanja efikasnosti i efektivnosti visokoobrazovnih sustava dolazi upravo iz tih zemalja. U nastavku su prikazane metode korištene u doktorskoj disertaciji za formiranje empirijskog modela vrednovanja efikasnosti visokoobrazovnih institucija ekonomskog usmjerenja.

5.1. ANALIZA OMEĐIVANJA PODATAKA KAO METODA VREDNOVANJA RELATIVNE EFIKASNOSTI U INSTITUCIJAMA JAVNOG SEKTORA

Analiza omeđivanja podataka (AOMP) je neparametrijska metoda (nije potrebna direktna zavisnost između inputa i outputa) koja se bazira na linearnom programiranju. Ona služi za omeđivanje promatranih podataka sa svrhom određivanja granice najbolje prakse. Kod korištenja metoda u kojima se pojavljuju višestruki inputi i višestruki outputi, zbog kompleksnosti njihovih relacija, uputno je koristiti neparametrijski pristup. Za primjer se može uzeti regresijska analiza koja vrši optimizaciju za sve donosioce odluke (DO) skupno i ona se

koristi kada nas zanimaju opća obilježja DO. AOMP koristi niz optimizacija na svakom pojedinom DO i koristi se kada se pojedini DO uspoređuje s jedinicama koje su mu slične (Šegota, 2003). Ova metoda prvotno je namijenjena vrednovanju efikasnosti DO u javnom sektoru, ali se je uskoro počela primjenjivati i izvan javnog sektora gdje neke druge metode nisu davale zadovoljavajuće rezultate. DO je subjekt koji pretvara svoje resurse (inpute) u rezultate poslovanja (outpute). Danas se AOMP primjenjuje u zdravstvu (Tsai, Mar Molinero, (2002), Ozcan, 2008)), školstvu (Thanassoulis i dr. (2011), Johnes, Yu (2008), Abbott, Doucouliagos (2003), Hosseinzadeh Saljooghi, Mahallati Rayeni (2011)), energetici (Vlahinić – Dizdarević, Šegota, 2012), zračnom prometu (Jahanshaloo i dr., 2012) i mnogim drugim područjima. Kako bi se jednostavnije predočio proces vrednovanja relativne efikasnosti donosioca odluke primjenom AOMP-a, isti je prikazan sljedećom shemom.

Shema 15: Proces vrednovanja efikasnosti korištenjem analize omeđivanja podataka



Izvor: Izrada autorice

U Hrvatskoj se u posljednjih desetak godina AOMP počela primjenjivati u širem krugu djelatnosti. Koristila u istraživanju relativne efikasnosti prodajnih objekata u maloprodaji (Šegota, 2003, 2008), ocjenjivanju relativne efikasnosti hrvatskih županija u turizmu (Rabar, Blažević, 2011), mjerenju relativne efikasnosti hrvatskih carinskih službi (Benazić, 2012), ocjenjivanju relativne efikasnosti poslovanja hrvatskih bolnica (Rabar, 2010), mjerenju relativne efikasnosti u šumarstvu (Šporčić, Šegotić, Martinić (2006), Šporčić, Martinić, Landekić, Lovrić (2008), Šporčić, Martinić, Šegotić (2007)).

AOMP je snažan i široko korišten alat jer omogućuje korištenje više inputa i više outputa koji mogu biti izraženi u različitim jedinicama. Ova analiza mjeri relativnu efikasnost na način da u odnos stavlja inpute i outpute pomnožene s težinama koje maksimiziraju njihov omjer za svakog DO.

Relativna efikasnost podrazumijeva međusobnu usporedbu DO na način da se oni relativno neefikasni uspoređuju s onim relativno efikasnim. AOMP ne daje ocjenu apsolutne efikasnosti jer to podrazumijeva jasno definiran odnos između inputa i outputa gdje je poznata razina efikasnosti koju je teorijski moguće ostvariti. S obzirom da je to uglavnom teško utvrditi u većini segmenata djelovanja, pa tako i u visokom obrazovanju, češće se koristi relativna efikasnost kao mjera usporedbe između sličnih jedinica. AOMP koristi poznate inpute i outpute, pri čemu nije potrebno poznavati njihovu direktnu povezanost. Temeljem tih podataka donosi sud o relativnoj efikasnosti svakog pojedinog DO stavljajući ga u odnos sa setom ostalih promatranih DO. Oni koji ostvare optimalnu vrijednost $\theta = 1$ (100% relativno efikasni) smatraju se relativno efikasnim, pri čemu θ označuje razinu efikasnosti. Oni DO kojima je rezultat efikasnosti manji od jedan smatraju se relativno neefikasnim ($0 \leq \theta < 1$). Relativno efikasan je onaj DO koji ne može smanjiti niti jedan svoj input, a da pritom ne mora smanjiti neki od outputa ili povećati neki od preostalih inputa, odnosno da ne može povećati niti jedan svoj output, a da pritom ne mora povećati neki od svojih inputa ili smanjiti neki od ostalih outputa

Odnos između inputa i outputa otkriva razinu relativne efikasnosti svakog pojedinog DO uključenog u analizu. Ukoliko postoje informacije o cijenama ili troškovima kojima se mogu izraziti inputi i outputi, ta se informacija može koristiti. Problem je u tome što ti podaci često dostupni jedino u privatnim poduzećima i institucijama dok u poduzećima javnog sektora cijene ili ne postoje ili se ne mogu uzeti kao jedinica koja govori o vrijednosti javnog dobra, a troškovi se često marginaliziraju. Zbog nedostatka cijena u javnom sektoru, AOMP najčešće mjeri tehničku efikasnost. Dobiveni rezultat pruža informaciju o tome je li korištenje inputa u proizvodnji outputa relativno efikasno ili ne, ali često ne i informaciju mogu li relativno efikasni DO smanjiti troškove kako bi se ostvarile veće izlazne veličine (McMillan, Datta, 1998). Zbog porasta interesa javnosti za efikasnijim trošenjem javnih sredstava, spomenutim kategorijama se pridaje sve veća pažnja. U visokom obrazovanju neki segmenti cijena i troškova su poznati te kao takvi sve češće postaju inputi ili outputi istraživanja efikasnosti visokog obrazovanja.

Osnovni modeli u analizi omeđivanja podataka

Začetnikom AOMP u literaturi se navodi Farrell (1957) koji je prezentirao novi pristup za procjenu efikasnosti iz kojega se je kasnije razvila AOMP. Prema njemu se produktivna efikasnost (još je naziva ekonomska ili ukupna efikasnost) sastoji od dva dijela: tehničke

(mogućnost poduzeća da ostvare maksimalne outpute s raspoloživim inputima) i alokativne (mogućnost poduzeća da koriste inpute u optimalnim omjerima) efikasnosti. Kada se koncept tehničke efikasnosti primijeni na razini sektora, dobije se strukturalna efikasnost. Na temelju Farrellova istraživanja, Charnes, Cooper i Rhodes (1978) preformulirali su njegovu originalnu zamisao u oblik matematičkog programiranja na način da su omogućili izračun rezultata relativne efikasnosti za svakog DO te su time utemeljili AOMP kakvu danas poznajemo. Zato se njih i smatra začetnicima ove metodologije.

CCR model

Charnes, Cooper i Rhodes (1978) predložili su da se relativna efikasnost svakog DO računa kao odnos između inputa i outputa pomnoženih s pripadajućim težinama koje maksimiziraju njihov odnos.

Postoje dvije verzije CCR modela, inputu orijentiran model (ostvarivanje danih outputa koristeći minimalne inputime) i outputu orijentirani model (ostvarivanje maksimalnih outputa koristeći dane inpute). Originalni rad Charnesa, Coopera i Rhodesa (1978) podrazumijevao je konstantne prinose (constant returns to scale - CRS) i inputu usmjeren model. CRS podrazumijeva da će povećanje inputa rezultirati proporcionalnom povećanjem outputa (npr. ukoliko 10 znanstvenika godišnje publicira 20 radova, 20 znanstvenika će godišnje publicirati 40 radova).

AOMP se obično provodi u dvije faze. Njima je moguće odrediti višak inputa ili manjak outputa. U nastavku su objašnjene obje faze *CCR inputu orijentiranog modela*.

1. faza:

U ovoj fazi određuje se relativna efikasnost DO i vrijednosti pripadajućih težina inputa i outputa.

Korištenje višestrukih inputa i outputa u AOMP može se prikazati sljedećim omjerom (Cooper, Seiford, i Tone, 2007):

$$\frac{\sum_{r=1}^s u_r y_r}{\sum_{i=1}^m v_i x_i} = \frac{u_1 y_1 + u_2 y_2 + \dots + u_s y_s}{v_1 x_1 + v_2 x_2 + \dots + v_m x_m}$$

Pritom je:

y_r = količina outputa r

u_r = težina outputa r

x_i = količina inputa i

v_i = težina inputa i

Težine mogu biti varijabilne (deriviraju se iz korištenih podataka) ili fiksne (unaprijed definirane).

CCR model je zamišljen na način da se formiraju virtualni inputi i virtualni outputi te odrede težine koje maksimiziraju njihov omjer (Cooper, Seiford, i Tone, 2007):

$$\text{Virtualni output} = v_1 x_{1o} + \dots + v_m x_{mo}$$

$$\text{Virtualni input} = u_1 y_{1o} + \dots + u_s y_{so}$$

Virtualni input jednak je zbroju umnožaka pojedinih inputa i pripadajućih težina, dok je virtualni output jednak zbroju umnožaka pojedinih outputa i pripadajućih težina. Izraz „virtualni“ koristi se iz razloga što se dovode u vezu različite kategorije inputa, odnosno outputa koji su izraženi u različitim jedinicama.

Potom se određuju težine kako bi se maksimizireo sljedeći omjer:

$$\frac{\text{virtualni output}}{\text{virtualni input}}$$

Ukoliko težine nisu unaprijed određene, one se izvode iz raspoloživih podataka. Optimalne težine se razlikuju između DO jer se svakom DO pripisuju one težine koje maksimiziraju njegovu funkciju.

Matrica inputa (X) sastoji se od m inputa i n DO, a matrica outputa (Y) od s outputa i n DO koji se mogu se prikazati na sljedeći način:

$$X = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{pmatrix} \quad (5.1)$$

$$Y = \begin{pmatrix} y_{11} & y_{12} & \dots & y_{1n} \\ y_{21} & y_{22} & \dots & y_{2n} \\ \dots & \dots & \dots & \dots \\ y_{s1} & y_{s2} & \dots & y_{sn} \end{pmatrix} \quad (5.2)$$

U CCR modelu frakcijskim (razlomljenim) programiranjem (FP_0) rješava se sljedeća jednačba s ciljem dobivanja težina za inpute (v_i , za $i = 1, 2, \dots, m$) i za outpute (u_r , za $r = 1, 2, \dots, s$).

$$(FP_0) \quad \max \theta = \frac{u_1 y_{10} + u_2 y_{20} + \dots + u_s y_{s0}}{v_1 x_{10} + v_2 x_{20} + \dots + v_m x_{m0}} \quad (5.3)$$

Maksimalnu vrijednost θ u izrazu (5.3) potrebno je tražiti uvažavajući sljedeće uvjete:

$$\frac{u_1 y_{1j} + \dots + u_s y_{sj}}{v_1 x_{1j} + \dots + v_m x_{mj}} \leq 1 \quad (j = 1, \dots, n) \quad (5.4)$$

$$v_1, v_2, \dots, v_m \geq 0 \quad (5.5)$$

$$u_1, u_2, \dots, u_s \geq 0 \quad (5.6)$$

Uvjeti ograničavaju vrijednost omjera virtualnih inputa i virtualnih outputa na maksimalnu vrijednost 1 za svakog DO. Cilj je dobiti one težine koje maksimiziraju omjer DO čija se relativna efikasnost procjenjuje (DO_0).

Moguće je izvršiti zamjenu frakcijskog programiranja (FP_0) ekvivalentnim linearnim programiranjem (LP_0) na sljedeći način (Cooper, Seiford, i Tone, 2007):

$$(LP_0) \quad \max \theta = \mu_1 y_{10} + \dots + \mu_s y_{s0} \quad (5.7)$$

Maksimalnu vrijednost θ u izrazu (5.7) potrebno je tražiti uvažavajući sljedeće uvjete:

$$v_1 x_{10} + \dots + v_m x_{m0} = 1 \quad (5.8)$$

$$\mu_1 y_{1j} + \dots + \mu_s y_{sj} \leq v_1 x_{1j} + \dots + v_m x_{mj} \quad (j = 1, \dots, n) \quad (5.9)$$

$$v_1, v_2, \dots, v_m \geq 0 \quad (5.10)$$

$$\mu_1, \mu_2, \dots, \mu_s \geq 0 \quad (5.11)$$

Ukoliko se pretpostavi optimalno rješenje (LP_0) koje se može napisati simbolima (θ^* , v^* , u^*), gdje se simboli v^* i u^* koriste umjesto vrijednosti iz uvjeta (5.10) i (5.11), moguće je definirati CCR efikasnost.

DO₀ je CCR efikasan ukoliko mu je $\theta^* = 1$ i ukoliko postoji barem jedna optimalna (v^*, u^*) gdje je $v^* > 1$ i $u^* > 1$. U suprotnom je DO₀ CCR neefikasan. Cilj je osigurati vrijednosti (v^*) i (u^*) koje maksimiziraju omjer DO₀.

Optimalno rješenje (θ^*) dobiveno linearnim programiranjem (LP_0) sadrži skup najpovoljnijih (optimalnih) težina za DO₀ (v^*, u^*) , a njegova jednadžba može se napisati na sljedeći način:

$$\theta^* = \frac{\sum_{r=1}^s u_r^* y_{r0}}{\sum_{i=1}^m v_i^* x_{i0}} \quad (5.12)$$

S obzirom da je nazivnik izraza (5.12) jednak 1 što je vidljivo iz uvjeta (5.8), izraz se može pisati na sljedeći način:

$$\theta^* = \sum_{r=1}^s u_r^* y_{r0} \quad (5.13)$$

2. faza:

U ovoj fazi se temeljem relativne efikasnosti definirane u 1. fazi traži referentni skup za svakog DO. Referentni skup čine relativno efikasni DO u odnosu na koje se ocjenjuje DO₀.

Pripadajući dvostruki linearni problem (eng. *dual linear problem – DLP₀*) ima sljedeći oblik:

$$(DLP_0) \quad \min \theta \quad (5.14)$$

uz sljedeće uvjete:

$$\theta x_0 - X\lambda \geq 0 \quad (5.15)$$

$$Y\lambda - y_0 \geq 0 \quad (5.16)$$

$$\lambda \geq 0 \quad (5.17)$$

gdje λ predstavlja semipozitivnu, odnosno nenegativnu vrijednost u skupu realnih brojeva.

Vrijednosti iz vektora λ biraju se na način da se zadovolje sljedeće jednakosti:

$$s^- = \theta x_0 - X\lambda, \quad s^- \geq 0 \quad (5.20)$$

$$s^+ = Y\lambda - y_0, \quad s^+ \geq 0 \quad (5.21)$$

gdje dopunske varijable s^- i s^+ predstavljaju semipozitivne vrijednosti u skupu realnih brojeva.

Temeljem spoznaja o θ^* iz prve faze, rješava se sljedeći LP:

$$\max_{\lambda, s^-, s^+} \omega = s^- + s^+ \quad (5.22)$$

Cilj druge faze je u pronalasku onog rješenja koje maksimizira zbroj viškova inputa i manjkova outputa uz održavanje uvjeta $\theta = \theta^*$.

Temeljem prethodno navedenog može se zaključiti da je DO_0 CCR efikasan ukoliko je zadovoljio sljedeće uvjete: $\theta^* = 1$, $s^- = 0$ i $s^+ = 0$. U suprotnom je neefikasan.

Za neefikasne DO definira se referentni skup E_0 . On se bazira na rješenju maksimalne dopunske varijable dobivene nakon rješavanja faze 1 i 2 na sljedeći način:

$$E_0 = \{j \mid \lambda_j^* > 0\} \quad (j \in \{1, \dots, n\}) \quad (5.23)$$

Pritom se optimalno rješenje prikazuje izrazima:

$$\theta^* x_0 = \sum_{j \in E_0} x_j \lambda_j^* + s^{-*} \quad (5.24)$$

$$y_0 = \sum_{j \in E_0} y_j \lambda_j^* - s^{+*} \quad (5.25)$$

Iz prethodnih izraza vidljivo je da relativna efikasnost od (x_0, y_0) za DO_0 može porasti ukoliko se vrijednosti inputa smanjuju proporcionalno s omjerom θ^* uz uvjet otklanjanja viškova inputa (s^{-*}), odnosno ukoliko se vrijednosti outputa povećaju s manjkovima outputa (s^{+*}).

Ukupno poboljšanje inputa Δx_0 i outputa Δy_0 može se izračunati na sljedeći način:

$$\Delta x_0 = x_0 - (\theta^* x_0 - s^{-*}) = (1 - \theta^*)x_0 + s^{-*} \quad (5.26)$$

$$\Delta y_0 = s^{+*} \quad (5.27)$$

Temeljem prethodnih izraza dobivena je formula za poboljšanje koja se zove CCR–projekcija:

$$\hat{x}_0 = x_0 - \Delta x_0 = \theta^* x_0 - s^{-*} \leq x_0 \quad (5.28)$$

$$\hat{y}_0 = y_0 - \Delta y_0 = y_0 + s^{+*} \geq y_0 \quad (5.29)$$

CCR projekcija daje informaciju o potrebnim smanjivanjima inputa ili povećavanjima outputa koju neefikasan DO_0 mora izvršiti kako bi došao na granicu efikasnosti.

CCR outputu orijentiran model formulira se na sljedeći način:

$$(DLPO_0) \max \eta \quad (5.30)$$

uz sljedeće uvjete:

$$x_0 - X\mu \geq 0 \quad (5.31)$$

$$\eta y_0 - Y\mu \leq 0 \quad (5.32)$$

$$\mu \geq 0 \quad (5.33)$$

Pritom se optimalno rješenje modela ($DLPO_0$) može direktno dobiti iz rješenja inputu orijentiranog CCR modela. (5.31) i (5.32) dobivaju se dijeljenjem (5.15), odnosno (5.16) s θ pri čemu je:

$$\eta = \frac{1}{\theta} \quad (5.34)$$

$$\mu = \lambda \cdot \eta = \frac{\lambda}{\theta} \quad (5.35)$$

Dopunske varijable u CCR output orijentiranom modelu (t^- i t^+) dobiju se dijeljenjem (5.20), odnosno (5.21) s θ pri čemu se dobije:

$$t^- = x_0 - X\mu, \quad t^- \geq 0 \quad (5.36)$$

$$t^+ = Y\mu - \eta y_0, \quad t^+ \geq 0 \quad (5.37)$$

Može se zaključiti da svaki DO koji se pokaže relativno efikasan prema CCR inputu orijentiranom modelu mora biti relativno efikasan i prema CCR outputu orijentiranom modelu. Razlika u izboru ova dva modela očitovat će se u projekcijama (smanjenje inputa čiju mjeru predstavlja θ^* ili povećanje outputa čiju mjeru predstavlja η^* čija vrijednost je ≥ 0).

Dualni problem ($DLPO_0$) prikazan je modelom:

$$(LPO_0) \min px_0 \quad (5.38)$$

uz sljedeće uvjete:

$$qy_0 = 1 \quad (5.39)$$

$$-pX + qY \leq 0 \quad (5.40)$$

$$p \geq 0, \quad q \geq 0 \quad (5.41)$$

pri čemu su komponente vektora p i q korištene kao varijable, a dobivene su dijeljenjem s θ :

$$p = \frac{v}{\theta} \quad (5.42)$$

$$q = \frac{u}{\theta} \quad (5.43)$$

Moguće je izvršiti proširenje CCR modela prikazanog u dvije faze dodajući još jednu, 3. fazu. Razlog tome je mogućnost projekcije relativno neefikasnog DO na efikasnu granicu daleko od njegovih ostvarenih vrijednosti. To je problem jer se DO susreće s problemima s obzirom na moguće velike razlike između ostvarenih vrijednosti i vrijednosti potrebnih za ostvarivanje relativne efikasnosti. Zato je poželjno projekciju izvršiti na onu točku na granici efikasnosti koja ima najslabije vrijednosti inputa i outputa DO_0 . U ovoj fazi se rješava linearni program za svakog neefikasnog DO (Cooper, Seiford, i Tone, 2007):

$$\min \omega \quad (5.44)$$

uz sljedeće uvjete:

$$\theta^* x_{i0} = \sum_{j \in R} x_{ij} \lambda_j + \delta_i^- x_{i0} \quad (i=1, \dots, m) \quad (5.45)$$

$$y_{r0} = \sum_{j \in R} y_{rj} \lambda_j + \delta_r^+ y_{r0} \quad (i=1, \dots, s) \quad (5.46)$$

$$\delta_i^- \leq p \quad (i=1, \dots, m) \quad (5.47)$$

$$\delta_r^+ \leq q \quad (i=1, \dots, s) \quad (5.48)$$


$$p \leq \omega, \quad q \leq \omega \quad (5.49)$$

$$\lambda_j \geq 0, \quad \delta_i^- \geq 0, \quad \delta_r^+ \geq 0, \quad (\forall j, i, r)$$

Pritom θ^* predstavlja optimalnu vrijednost funkcije cilja iz 1. faze, δ_i^- relativni omjer devijacije u odnosu na x_{i0} , dok δ_r^+ predstavlja relativni omjer devijacije u odnosu na y_{r0} .

Kako bi se jednostavnije dočarala razlika između oblika CCR inputu i outputu usmjerenog modela, dan je sljedeći prikaz:

Grafikon 8: CCR inputu i outputu usmjeren model



Izvor: Izrada autorice

Iz grafikona je vidljiva razlika u obliku modela ovisno o orijentaciji. Razlog je taj što u inputu usmjerenom modelu DO treba minimizirati inpute (uz dani output) kako bi ostvario čim višu relativnu efikasnost, pa je zbog toga krivulja okrenuta prema ishodištu. U drugom slučaju kada se radi o output orijentaciji, DO kako bi povećali svoju relativnu efikasnost trebaju čim više povećati svoj output (uz dane inpute) te se trebaju kretati u suprotnom smjeru od ishodišta. DO povezani linijom su efikasni, a sama linija predstavlja granicu efikasnosti.

BCC model

Nakon što su Charnes, Cooper i Rhodes (1978) predstavili CCR model na ovome području je došlo do velikog rasta broja publikacija jer je AOMP prepoznata kao jednostavan alat za vrednovanje relativne efikasnosti. Značajnu nadogradnju ovome istraživanju napravili su Banker, Charnes i Cooper (1984) prezentirajući varijabilne prinose (variable returns to scale – VRS) i outputu usmjeren model (BCC model). CRS koji se vežu uz CCR model podrazumijeva proporcionalno povećanje outputa kao rezultat povećanja inputa (npr. ukoliko 10 znanstvenika godišnje publicira 20 radova, 20 znanstvenika će godišnje publicirati 40 radova), dok kod VRS povećanje inputa ne mora rezultirati proporcionalnim povećanjem outputa već prinosi mogu biti rastući ili padajući (20 znanstvenika će publicirati ili više ili manje od 40 radova godišnje). Jedina razlika između CCR i BCC modela je u uvjetu koji je dodan BCC modelu, a glasi:

$e\lambda = \sum_{j=1}^n \lambda_j = 1$. S obzirom da je postavljen uvjet $\lambda_j \geq 0$ za sve j , nametnut je uvjet konveksnosti kojim se na dopustive načine skup odabranih DO može kombinirati (Šegota, 2003). Kao i CCR model, i BCC model može biti inputu ili outputu usmjeren.

Inputu usmjeren BCC model kao i CCR model vrši se u dvije faze te na taj način određuje relativnu efikasnost DO_0 :

1. faza (minimizira se θ_B):

$$(BCC_0) \min \theta_B \quad (5.50)$$

uz sljedeće uvijete:

$$\theta_B x_0 - X\lambda \geq 0 \quad (5.51)$$

$$Y\lambda \geq y_0 \quad (5.52)$$

$$e\lambda = 1 \quad (5.53)$$

$$\lambda \geq 0 \quad (5.54)$$

Pritom θ_B označava skalar. Pripadajući dualni problem prikazan je u drugoj fazi:

2. faza (maksimizira se zbroj viškova inputa i manjkova outputa):

$$\max z = uy_0 - u_0 \quad (5.55)$$

uz sljedeće uvijete:

$$vx_0 = 1 \quad (5.56)$$

$$-vX + uY - u_0 e \leq 0 \quad (5.57)$$

$$v \geq 0, \quad u \geq 0 \quad (5.58)$$

pritom skalari z i u_0 mogu biti pozitivni, negativni i jednaki nuli, tako da upravo varijabla u_0 čini razliku između CCR i BCC modela.

Ukoliko optimalno rješenje BCC_0 ($\theta_B^*, \lambda^*, s^{-*}, s^{+*}$) zadovoljava uvijet da je $\theta_B^* = 1$ i pritom su dopunske varijable (s^{-*} i s^{+*}) jednake nuli DO_0 smatra se efikasnim. U suprotnom je neefikasan.

Za svaki BCC – relativno neefikasni DO određuje se referentni skup E_0 (5.23) koji se bazira na optimalnom rješenju λ^* .

Input usmjereni BCC model razlikuje se od outputu usmjerenog BCC modela po tome što prvi minimizira θ_B kako bi se ostvarilo proporcionalno smanjenje inputa dok potonji maksimizira η_B kako bi se ostvarilo proporcionalno povećanje outputa. Pritom svi DO koji su se pokazali relativno efikasnim u BCC inputu orijentiranom modelu biti će relativno efikasni i u BCC outputu orijentiranom modelu.

BCC outputu orijentirani model može se prikazati kroz program u obliku ovojnice na sljedeći način:

$$(BCC - O_0) \max \eta_B \quad (5.59)$$

uz sljedeće uvijete:

$$X\lambda \leq x_0 \quad (5.60)$$

$$\eta_B y_0 - Y\lambda \leq 0 \quad (5.61)$$

$$e\lambda = 1 \quad (5.62)$$

$$\lambda \geq 0 \quad (5.63)$$

Pripadajući dualni program od $BCC-O_0$ prikazuje se na sljedeći način:

$$\min z = vx_0 - v_0 \quad (5.64)$$

uz sljedeće uvijete:

$$uy_0 = 1 \quad (5.65)$$

$$vX - uY - v_0 e \geq 0 \quad (5.66)$$

$$v \geq 0, u \geq 0 \quad (5.67)$$


Pritom je skalar v_0 u obliku ovojnice povezan s $e\lambda = 1$.

Prema Charnesu i dr. (1994) AOMP može imati tri različite orijentacije:

- Input orijentirane modele gdje DO pokušavaju sa što manjom količinom inputa ostvariti danu količinu outputa,
- U output orijentiranim modelima DO pokušavaju sa danom količinom inputa maksimizirati svoj output .
- U bazno orijentiranim modelima se od DO traži da proizvede optimalnu kombinaciju inputa i outputa.

Odabir usmjerenja ovisi isključivo o specifičnostima promatranih pojedinih DO i cilju s kojim se vrši analiza. Na sljedećem grafikonu prikazane su projekcije DO na granicu efikasnosti ovisno o izabranoj orijentaciji.

Grafikon 9: Projekcije na granicu efikasnosti ovisno o orijentaciji



- A: projekcija s input orijentacijom modela
- B: projekcija s baznom orijentacijom modela
- C: projekcija s output orijentiranim modelom

Izvor: Autorica prema: Ryerson University (n.d.). Tutorial in DEA, dostupno na: <http://www.ryerson.ca/~mhababou/DEAtutorial/deatutorial.html> (4.09.2013)

Kako bi se jednostavnije dočarala razlika između CRS i VRS formulacije, na sljedećem grafikonu dan je prikaz efikasnosti prema navedenim modelima. Na prikazu je korištena input orijentacija i vidljivo je kako broj relativno efikasnih donosioca odluke snažno varira ovisno o odabranom modelu. CRS formulacija prikazana je ravnom linijom koja polazi od ishodišta O i prolazi točkom A koja predstavlja relativno efikasnog DO. S druge strane VRS formulaciju tvori konkavna linija koja po dijelovima ima linearan oblik proizvodne granice te na taj način omeđuje točke A, B i C koje predstavljaju relativno efikasne DO. Vidljiva je značajna razlika vezana za izbor same formulacije jer je korištenjem varijabilnih prinosa veći broj DO ocijenjen relativno efikasnim nego korištenjem konstantnih prinosa. Čak i donosioci odluke koji su prema VRS formulaciji relativno neefikasni (D, E i F), korištenjem CRS formulacije njihova efikasnost dodatno opada.

- U analizi postoji mogućnost korištenja višestrukih inputa i outputa koji mogu biti izraženi u različitim mjernim jedinicama. Zbog složenosti u vezama između inputa i outputa, za razliku od AOMP, veliki broj metodologija ne može se nositi s ovim problemom.
- AOMP omogućuje mjerenje relativne efikasnosti što bi značilo da se DO pozicioniraju jedni u odnosu na druge. Iako se ponekad ovo obilježje zamjera AOMP (jer ne daje iznos apsolutne efikasnosti), ono se češće ističe kao prednost jer ispred relativno neefikasnih DO stavlja realne granice (ne teorijski postavljene) koje je moguće dostići.
- Ne postoje ograničenja oko odabira inputa i outputa.
- Nije potrebno pretpostavljati formu funkcije i direktne veze između inputa i outputa

Pored brojnih koristi koje omogućuje korištenje ove metode, ističu se i njezina ograničenja. Često upravo prednosti koje korištenje AOMP pruža, istovremeno mogu biti i njezina ograničenja (Ryerson University, n.d.).

- AOMP omogućuje uvid u relativnu efikasnost svakog DO, ali ne daje informacije o apsolutnoj efikasnosti. Relativno efikasni DO su najefikasniji između onih promatranih, a ne u usporedbi s idealnom mogućom teorijskom razinom efikasnosti. Zato relativno efikasan DO istovremeno može biti apsolutno neefikasan.
- Kao ograničenje često se navodi i nemogućnost rangiranja relativno efikasnih DO jer svi imaju rezultat relativne efikasnosti jednak 1 (100%). Daljnjim unaprjeđenjem AOMP-a, u analizu je uvedena mogućnost daljnjeg rangiranja relativno efikasnih DO putem tzv. superefikasnosti kojom se mjeri maksimalna moguća promjena u inputima i outputima koja se može dogoditi kako bi promatrani DO ostao efikasan. Što je ta mjera veća, DO je više rangiran unutar efikasnih DO (razina efikasnosti u tim slučajevima prelazi 1) (Anderson, Peterson, 1993). Mjerom superefikasnosti spomenuto je ograničenje moguće otkloniti.
- Izbor inputa i outputa snažno utječe na rezultat kao i svaki dodani ili oduzeti DO. AOMP će dati uvid u razinu relativne efikasnosti putem rezultata relativne efikasnosti, ali neće pružiti potpunu informaciju da li je izbor samih inputa i outputa ispravan. Također, moguća je nesigurnost oko toga koje su varijable podložne kontroli DO, a koje nisu što također može djelovati na način da komplicira analizu (McMillan, Datta, 1998).

- Pridruživanje težinskih faktora vrši se fleksibilno na način da se svakom DO pridružuju one težine koje mu omogućuju najbolji rezultat relativne efikasnosti. Time se može dogoditi da se veće težine pridodaju inputima i outputima manjeg značaja, a manja težina se pridoda onim ključnim. Zbog toga su se razvila poboljšanja u modelu (Dyson i Thanassoulis, 1988), (Charnes i dr. 1989) na način da se mogu postaviti ograničenja težina i na taj način onemogućiti da se manje važnim varijablama pridoda prevelika ili onim važnijim premala važnost (Salerno, 2006).
- DO moraju biti homogeni na način da sa sličnim inputima korištenjem sličnih tehnologija stvaraju slične outpute. Usporedba relativne efikasnosti različitih DO neće dati značajne rezultate.
- Ukoliko broj DO nije dovoljan, analiza neće dati signifikantne rezultate (rezultati će biti bolji od realnih jer će previše DO biti na granici efikasnosti). Pravilo je da broj DO treba biti barem tri do četiri puta veći od sume broja inputa i outputa kako bi se dobili zadovoljavajući rezultati.
- Analiza ne odvaja šum u podacima od neefikasnosti
- S obzirom da se radi o neparametrijskoj metodi teško je provesti statističko testiranje hipoteze

Iako ova metodologija nije savršena jer ima brojna ograničenja, široko je prihvaćen i često korišten alat u vrednovanju relativne efikasnosti prvenstveno javnih, ali i privatnih poduzeća i ustanova. Pažljivim pristupanjem analizi veliki broj ograničenja može se prevladati i njenim korištenjem mogu se dobiti korisni rezultati. Zbog toga je ona jedna od najčešće korištenih metoda vrednovanja relativne efikasnosti obrazovnoga sustava.

5.2. KLASITER ANALIZA KAO METODA IDENTIFICIRANJA I KLASIFICIRANJA SKUPINE RAZLIČITIH OBJEKATA

Klaster analiza je multivarijantna statistička metoda kojom se identificiraju i klasificiraju grupe unutar skupine različitih objekata temeljem određenih varijabli te se kao takva primjenjuje u različitim znanstvenim područjima. Značajnija primjena ove metode, pod utjecajem razvoja računala, zabilježena je šezdesetih godina dvadesetog stoljeća. Klaster analizom žele se utvrditi homogene grupe (klasteri) pri čemu grupna pripadnost promatranih objekata nije poznata kao ni broj grupa (Mooi, Sarstedt, 2011). Objekti mogu biti osobe, poduzeća, ustanove i sl. U ovoj doktorskoj disertaciji objekti su 31 visokoobrazovna institucija ekonomskog usmjerenja (u analizi omeđivanja podataka isti su definirani kao DO). Klasterizacija se koristi za kategorizaciju jedinica koje se analiziraju temeljem njihove sličnosti ili različitosti promatranih obilježja. Povezivanje objekata vrši se temeljem definiranja matrice udaljenosti koja utvrđuje poveznice između različitih objekata temeljem kojih se oni najbliži povezuju u grupe. Mjerama udaljenosti utvrđuje se različitost između objekata temeljem osobina koje se mjere.

Prije pristupanja samom procesu klaster analize, potrebno je odrediti uzorak (objekte) na kojemu će analiza biti provedena. Nakon definiranja uzorka, pristupa se odabiru varijabli (osobina, obilježja objekata) temeljem čijih sličnosti i razlika će se uzorak dijeliti u homogene skupine. Varijable korištene u analizi mogu biti intervalne, ordinalne ili kategorijske (Cornish, 2007). Pri izboru varijabli bitno je da se njihov izbor temelji na teoriji ili modelu formiranom za potrebe analize kako bi se grupiranju pristupilo sa smislom. Sljedeći korak odnosi se na odluku o transformaciji varijabli. Ukoliko varijable nisu standardizirane (rezultati su prikazani različitim mjernim ljestvicama), predlaže se njihova standardizacija kako bi se udaljenosti između objekata mogle čim točnije odrediti. Sljedeći korak odnosi se na odabir mjere udaljenosti, odnosno sličnosti. Različite metode udaljenosti/sličnosti pridaju različiti značaj karakteristikama varijabli. Postoji više načina računanja udaljenosti i sličnosti (korelacije) između vektora $x=(x_1, x_2, \dots, x_p)$ i $y=(y_1, y_2, \dots, y_p)$, a oni najpoznatiji su prikazani u Tablici 18.

Tablica 18: Pregled mjera udaljenosti i sličnosti


Mjere udaljenosti		
Euklidska	$d(x, y) = \sqrt{\sum (x_i - y_i)^2}$	Korijen iz sume kvadriranih razlika vrijednosti za svaku varijablu
Kvadrirana euklidska	$d(x, y) = \sum (x_i - y_i)^2$	Suma kvadriranih razlika vrijednosti za svaku varijablu
Manhattan	$d(x, y) = \sum_i^n x_i - y_i $	Suma apsolutnih razlika vrijednosti za sve varijable.
Chebychev	$d(x, y) = \max (x_i - y_i) $	Maksimalna apsolutna razlika između dvije vrijednosti u bilo kojoj od varijabli.
Minkowski	$d(x, y) = \sqrt[p]{\sum_i^n x_i - y_i ^p}$	p-ti korijen sume apsolutnih razlika između svih parova vrijednosti, potenciranih na p-tu potenciju za sve
Mjere sličnosti		
Cosine	$d(x, y) = \frac{\sum_i^n (x_i y_i)}{\sqrt{\sum_i^n (x_i)^2 \sum_i^n (y_i)^2}}$	Kosinus vektora za dvije varijable
Pearson	$d(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (x_i - \bar{x})^2}}$	Mjera linearnog odnosa (povezanosti) između dvije varijable

Izvor: Katedra za psihometriju (n.d.). Klaster analiza, dostupno na:

http://www.ffzg.unizg.hr/psiho/phm/nastava/pmm/KLASTER_SAZETAK_PREDAVANJA_ZA_STUDENTE.DOC (7.06.2015); Filozofski fakultet Sveučilišta u Zagrebu (n.d.). Primjena multivarijantnih metoda, Klaster analiza, dostupno na: http://www.ffzg.unizg.hr/psiho/phm/nastava/pmm/KLASTER_ANALIZA_PREZENTACIJA.PPT (3.06.2015)

Objekti koji su slični imaju male mjere udaljenosti dok su te mjere za različite objekte veće. Pored izbora mjere udaljenosti, bitno je izabrati i odgovarajuću metodu za formiranje klastera. Pri odabiru metoda klasterizacije najčešće se koriste hijerarhijske i nehijerarhijske metode. U ovom radu koristit će se hijerarhijske metode te će se zbog toga njima posvetiti pažnja. Hijerarhijske metode se unutar sebe dijele na aglomerativne i dijeleće. Aglomerativne polaze od pojedinačnih objekata koji se grupiraju u sve veće klastere, dok dijeleće polaze od svih objekata u jednom klasteru koji se dijele do pojedinih objekata (podgrupa) (Shema 16).

Shema 16: Postupak klasterizacije kod aglomerativnih i dijelećih hijerarhijskih metoda klaster analize



Izvor: Autorica

Hijerarhijska aglomerativna klaster analiza, korištena u radu, dominantno se koristi u znanstvenim istraživanjima. Ova metoda polazi od pojedinih objekata kao početnih klastera te svakim sljedećim korakom spaja po dva najbliža klastera. U prvom koraku se u klustere spajaju pojedinačni objekti dok se kasnije spajanje nastavlja s klasterima sačinjenim od više objekata. Spajanje se nastavlja dok se ne dođe do kriterija zaustavljanja (Kostić, Hedrih, 2005). Klasteri nakon što su formirani hijerarhijskom metodom ne mogu se dijeliti već ih je moguće daljnim postupkom isključivo spajati. Output klaster analize može se prikazati u obliku dijagrama u obliku stabla koji se naziva dendrogram (grč. *dendron* = stablo).

Kao karakteristike hijerarhijske aglomerativne klaster analize ističu se:

- 1) polazište nalazi od matrici sličnosti između objekata;
- 2) klasteri se formiraju sukcesivno, a način njihova formiranja može se prikazati grafičkim putem pomoću dendrograma;
- 3) s obzirom da se prilikom formiranja klastera u prvom koraku pojedinačni objekti promatraju kao samostalni klasteri, proces formiranja klastera se sastoji od $k-1$ koraka;
- 4) metoda je jednostavno razumljiva potencijalnim korisnicima.

Prilikom korištenja klaster analize pristupa se odabiru metode kojom će se različiti objekti povezati u klaster. Pritom valja napomenuti kako se sve metode baziraju na matricama udaljenosti ili sličnosti među objektima ($k \times k$), a razlikuju se sukladno načinu procjenjivanja udaljenosti između klastra. Razlikuju se sljedeće metode (Cornish (2007), Katedra za psihometriju (n.d.), Filozofski fakultet Sveučilišta u Zagrebu (n.d.):

1. **Metoda najbližih susjeda** (eng. *nearest neighbor* ili eng. *single linkage*): udaljenost između dva klastera definira se udaljenošću između dva najbliža člana (susjeda). Pritom su članovi čija se udaljenost procjenjuje pripadnici različitih klastera. Postupak povezivanja baziran je na minimalnoj udaljenosti između članova. Ovom metodom polazi se od pojedinačnih objekata te mjereći najkraću (najjaču) udaljenost dva odvojena objekta smješta u prvi klaster. Potom se pristupa traženju sljedeće najkraće udaljenosti. Objekti se mogu pridružiti već postojećem klasteru ili se formiraju nova dva klastera. Postupak se nastavlja sve dok svi objekti ne pozicioniraju unutar jednog klastera.
2. **Metoda najdaljih susjeda** (eng. *furthest neighbour* ili eng. *complete linkage*): postupak udaljenosti između dva klastera sličan je kao i kod metode najbližih susjeda, ali se ovdje procjenjuje udaljenost između dva najdalja člana (susjeda).
3. **Prosječna veza između grupa** (eng. *average linkage – UPGMA – eng. unweighted pair-group method using arithmetic averages*): Razlika između dva klastera definira se kao prosječna udaljenost između svih parova koji se mogu definirati između dva objekta.
4. **Prosječna veza unutar grupa** (eng. *average linkage within groups*): udaljenost između dva klastera definirana je kao prosječna udaljenost između svih objekata koji bi formirali novi klaster od dva postojeća klastera.
5. **Wardova metoda** (eng. *Ward's method*): Računaju se aritmetičke sredine za svaku varijablu svakog klastera. Potom se izračunava kvadrirana euklidska udaljenost do aritmetičke sredine klastera za svaki pojedini objekt nakon čega se ove udaljenosti sumiraju za sve članove klastera. Klasteri se formiraju na način da se spajaju oni klasteri za koje je ukupna (zajednička) suma ovih odstupanja najmanja.

Nakon odabira metode, s obzirom da se hijerarhijskom aglomerativnom metodom klasterizacije svi klasteri u zadnjem koraku spoje u jedan (kod dijeleće je obrnuto), potrebno je odrediti trenutak kada prekinuti proces klasterizacije. Sam trenutak prekida ovisi, prije svega, o

teorijskim postavkama istraživanja. Uputa je da se proces prekine u trenutku kada se klasteri počnu formirati od udaljenih klastera.

Nakon dobivanja konačnog broja klastera, potrebno je pristupiti validaciji te interpretirati rezultate. Validacija se može provoditi sljedećim postupcima (Filozofski fakultet Sveučilišta u Zagrebu, n.d.):

- a) Replikacija – rezultati se repliciraju na na drugom slučajno odabranom uzorku.
- b) Testiranje razlika između klastera na varijablama temeljem kojih su formirani - ovisno o broju varijabli i klastera provodi se multivarijatna analiza varijance, odnosno više jednostavnih analiza varijance ili diskriminacijske analize.
- c) Testiranje razlika između klastera na izabranim egzogenim varijablama – proces validacije je isti kao u b), ali se testiranje razlika između klastera vrši na egzogenim varijablama koje nisu prethodno korištene u procesu klasterizacije.
- d) Monte Carlo metode – komplicirani postupci usporedbe dobivenog rezultata sa simulacijom na slučajno generiranim brojevima.

Primjena klaster analize zabilježena je u području visokog obrazovanja. Zaldivar-Colado i dr. (2012) identificirati su relevantne varijable povezane s akademskim uspjehom te su objekte klasificirali u dvije skupine (uspješne i manje uspješne studente). Valadkhani, Worthington (2005) su proučavali istraživačku djelatnost 36 Australskih sveučilišta te su klaster analizom identificirali dvije grupe, bolju i lošiju. Entwistle i Brennan (1971) su uspoređivali sličnosti između studenata temeljem njihovih akademskih rezultata. Identificirali su 12 klastera studenata od kojih su 3 s visokim rezultatima, 3 s niskim rezultatima, a 6 s prosječnim rezultatima. Svaki klaster unutar sebe ima određene specifičnosti. Hsuan-Fu, Chia-Chi (2008) su klaster analizom identificirali 5 različitih grupa studenata s ciljem razvijanja različitih marketinških strategija kod privlačenja studenata na Državno sveučilište Chiayi u Tajvanu (National Chiayi University - NCYU). Pored prednosti koje klaster analiza pruža, ova metoda ima i određene nedostatke.

Prednosti i nedostaci klaster analize

Kao temeljna prednost klaster analize ističe se njezina široka primjenjivost u različitim znanstvenim područjima. Ova metoda omogućuje istraživačima da podatke koji na prvi pogled djeluju nepovezani i nemogući za interpretirati, reduciraju na način da ih povežu u homogene,

reprezentativne skupine temeljem čega se može doći do statistički važnih spoznaja. Kao jedan od najvećih nedostataka ove metode ističe se velika doza subjektivnih odluka istraživača. Naime, na rezultate veliku utjecaj ima odluka o kriterijima spajanja klastera (metode, mjere udaljenosti), kao i varijable korištene za mjerenje udaljenosti/sličnosti između objekata. U klaster analizi ne postoje mehanizmi kojima bi se razdvojile bitne od nebitnih varijabli. S obzirom da krajnji rezultat klaster analize u potpunosti ovisi o izabranim varijablama, istraživač mora vrlo pažljivo odabrati ključne varijable temeljem kojih će se objekti povezati u homogene grupe. Također, konačan broj klastera također je pod utjecajem subjektivne procjene istraživača. Pri definiranju broja klastera pristupa se njihovoj interpretaciji sa svrhom identificiranja značajki objekata koji čine klaster (Devčić, Tonković, Pražić, Župan (2012)). Zbog navedenih razloga, bitno je analizi pristupiti pažljivo i smisleno, uz potporu teorijskih i znanstvenih pretpostavki, definirati bitne segmente analize i izabrati ključne varijable.

5.3. BINARNA LOGISTIČKA REGRESIJA KAO MJERA IDENTIFIKACIJE KLJUČNIH ČIMBENIKA PRIPADNOSTI POJEDINOJ SKUPINI

Logistička regresija (engl. *logit regression*) vrsta je regresijske analize koja modelira odnos između zavisne varijable (kriterij), y , i jedne ili više nezavisnih varijabli (prediktori), x , na temelju procjene vjerojatnosti. Drugim riječima, ona je formulirana na način da predvidi i objasni kategorijske zavisne varijable (dihotomne, nemetričke) temeljem nezavisnih varijabli (mogu biti metričke i nemetričke). Logistička regresija predstavlja metodu kojim se predviđaju vjerojatnosti različitih mogućih ishoda kategorički postavljene zavisne varijable temeljem skupa nezavisnih varijabli, a koristi kada odnos između zavisne varijable i nezavisnih varijabli nije linearan. U doktorskoj disertaciji binarnom logističkom regresijom predvidjet će se vjerojatnost prelaska iz jednog klastera u drugi sukladno promjeni nezavisnih varijabli, x . Vrijednost 1 dodjeljuje se prediktorima koji ulaze u bolje rangirani klaster 1, a vrijednost 0 dodjeljuje se prediktorima koji ulaze u lošije rangirani klaster 2.


Logistička funkcija izražava se jednadžbom (Gujarati, Porter, 2009):

$$y = \frac{1}{1 + e^{-k(x-a)}} \quad (5.68)$$

gdje je k koeficijent nagiba funkcije, a a je vrijednost na apscisi pri kojoj $y = 0.5$ (grafikon 11). Vrijednost nezavisne varijable x je realan broj, $x \in \langle -\infty, +\infty \rangle$, dok je vrijednost zavisne varijable y između 0 i 1, $y \in \langle 0, 1 \rangle$. Standardni oblik logističke funkcije dobiva se stavljanjem $k = 1$ i $a = 0$ u jednadžbi (1), tako da slijedi (Gujarati, Porter, 2009):

$$y = \frac{1}{1 + e^{-x}} = \frac{e^x}{e^x + 1} \quad (5.69)$$

Grafikon 11: Logistička funkcija za različite vrijednosti parametara k i a



Izvor: Autorica

Jednadžba (5.69) predstavlja kumulativnu distribuciju logističke funkcije. Odnos između zavisne varijable, y , i nezavisne varijable, x , je nelinearan. Funkcija ima eksponencijalan rast kod negativnih vrijednosti x , nakon čega postupno usporava i prelazi u linearan rast u blizini $x = 0$, a kod pozitivnih vrijednosti x razlika između funkcije i $y = 1$ eksponencijalno se smanjuje. Zbog ovakvih se karakteristika logistička funkcija koristi u modeliranju rasta populacije, te za analizu različitih procesa u ekonomiji, biologiji, kemiji, informatici, geoznanostima, političkim znanostima, i drugima (Gujarati, Porter, 2009).

Funkcija y (5.69) predstavlja vjerojatnost postojanja određenog ishoda. Tada se vjerojatnost nepostojanja tog istog ishoda može odrediti kao $1 - y$. Omjer između vjerojatnosti postojanja

ishoda i vjerojatnosti nepostojanja tog ishoda predstavlja omjer izgleda (eng. *odds ratio*), $y/(1 - y)$, tj. (Gujarati i Porter, 2009)

$$\frac{y}{1-y} = \frac{1+e^x}{1+e^{-x}} = e^x \quad (5.70)$$

Rezultat prirodnog logaritma omjera izgleda je nezavisna varijabla, x , tj. (Gujarati, Porter, 2009)

$$L = \ln\left(\frac{y}{1-y}\right) = x \quad (5.71)$$

Veličina L naziva se *logit*, a modeli koji se temelje na jednadžbi (5.71) nazivaju se *logit* modelima. Logit je linearan i u nezavisnim varijablama i u parametrima (Gujarati i Porter, 2009). Omjer izgleda može zauzeti vrijednosti između 0 i $+\infty$. Primjerice, ako je vjerojatnost postojanja ishoda 0,75, a vjerojatnost nepostojanja tog istog ishoda 0,25, omjer izgleda iznosi $0,75/0,25 = 3$. Logit omjera izgleda može zauzeti pozitivne i negativne vrijednosti i to negativne kada je omjer izgleda manji od 1, pozitivne kada je omjer izgleda veći od 1, a vrijednost 0 dobiva se kad je omjer izgleda jednak 1. U slučaju da je omjer izgleda 3, logit vrijednost iznosi $\ln(3) = 1,099$. Za razliku od vjerojatnosti i omjera izgleda, logit sadržava i pozitivne i negativne vrijednosti. Izrazi (5.70) i (5.71) su jednostavni oblici omjera izgleda i logit vrijednosti koji proizlaze iz standardnog oblika logističke funkcije. Općeniti oblik funkcije omjera izgleda i logit funkcije s logističkim koeficijentima glasi (Gujarati, Porter, 2009)

$$\frac{y}{1-y} = e^{b_0+b_1x_1+\dots+b_nx_n} \quad (5.72)$$

$$L = b_0 + b_1x_1 + \dots + b_nx_n \quad (5.73)$$

U linearnoj regresiji koeficijenti se određuju metodom najmanjih kvadrata, ali se u logističkoj regresiji koristi metoda maksimalne vjerodostojnosti. Metodom maksimalne vjerodostojnosti uzimaju se one vrijednosti koeficijenata za koje se rezultirajuća distribucija najbolje podudara s poznatim vrijednostima iz uzorka. U višestrukoj linearnoj regresiji, ako koeficijent nema utjecaja na zavisnu varijablu njegova vrijednost bit će 0. Koeficijenti u logit funkciji nazivaju se originalnim logističkim koeficijentima, a koeficijenti u omjeru izgleda nazivaju se eksponencijalnim logističkim koeficijentima. Pozitivna vrijednost originalnog koeficijenta

povećava vjerojatnost dok negativna vrijednost originalnog koeficijenta smanjuje vjerojatnost. Vrijednost originalnog koeficijenta 0 ne mijenja vjerojatnost jer odgovara vrijednosti od 1 u omjeru izgleda ($e^0 = 1$), odnosno vjerojatnosti od 0,50. Kod eksponencijalnih koeficijenata, vrijednost veća od 1 označava povećanje vjerojatnosti, vrijednost manja od 1 označava smanjenje vjerojatnosti, a vrijednost 1 označava vjerojatnost bez promjene. Eksponencijalni koeficijenti ne mogu imati negativne vrijednosti (Gujarati, Porter, 2009).

U binarnoj logističkoj regresiji, zavisna varijabla je dihotomna, odnosno njezine vrijednosti mogu biti 0 ili 1. Takav slučaj se često nailazi u praksi: muški ili ženski spol, ispravan ili neispravan proizvod, zaposlena ili nezaposlena osoba, proizvod A ili proizvod B, itd. U doktorskoj disertaciji vrijednosti 0 i 1 predstavljati će pripadnost određenom klasteru formiranom temeljem rezultata relativne efikasnosti visokoobrazovnih ustanova ekonomskog usmjerenja. Pritom će vrijednost 0 označavati lošije, a vrijednost 1 bolje rangirani klaster. Za svaku promatranu nezavisnu varijablu predviđa se u koju skupinu zavisne varijable pripada, 0 ili 1. U ovakvim analizama može se koristiti i višestruka linearna regresija, a dobivene vrijednosti zavisne varijable označavaju vjerojatnost. Međutim, u višestrukoj linearnoj regresiji pojavljuju se i vrijednosti različite od 0 i 1. U slučaju da se za promatrani proizvod x dobije vrijednost od 0,45, zaokružuje se na 0, a vrijednost od 0,55 zaokružuje se na 1. Problem višestruke linearne regresije su vrijednosti manje od 0, odnosno veće od 1, a koje se ne mogu interpretirati kao vjerojatnost. Stoga se, ispred višestruke linearne regresije, prednost daje logističkoj regresiji. Za razliku od višestruke linearne regresije, logistička regresija je osmišljena za predviđanje vjerojatnosti postojanja određenog ishoda. Za bilo koju vrijednost nezavisne varijable x , logistička regresija uvijek rezultira vrijednostima između 0 i 1, što nije slučaj u višestrukoj linearnoj regresiji. Linearni regresijski modeli nisu u stanju opisati nelinearnu vezu između nezavisnih i zavisnih varijabli kakva je prikazana na grafikonu 11. Drugim riječima, logistička regresija ne zahtijeva postojanje linearne veze između nezavisnih i zavisnih varijabli, što je preduvjet za linearne regresijske modele (Gujarati, Porter, 2009).

Za logističku regresiju karakteristična je kumulativna binomna distribucija, umjesto kumulativne normalne distribucije. Nadalje, u odnosu na nezavisnu varijablu, promjena zavisne varijable nije konstantna već dihotomna.

Osnovna svojstva binarne logističke regresije su (Gujarati, Porter, 2009):

- zavisna varijabla je dihotomna,
- zavisna varijabla transformira se u prirodni logaritam omjera izgleda,

- za promatranu nezavisnu varijablu predviđa se vjerojatnost njene pripadnosti jednoj od dviju skupina dihotomne varijable,
- nezavisne varijable moraju biti kontinuirane i u linearnoj vezi,
- veličina utjecaja nezavisne varijable na zavisnu varijablu ovisi o veličini regresijskih koeficijenata, pod uvjetom zanemarive kolinearnosti.

Logistička regresija nalazi široku primjenu u visokom obrazovanju. Koristi se kod analize odlučivanja između upisivanja ili neupisivanja visokoškolskih programa, kod izbora fakulteta, odustajanja ili završavanja studija, uspjeh na studiju, prebacivanja s jednog na drugi fakultet, razvojnih odluka unutar visokoškolskih institucija, itd (Cabrera, 1994).

Peng i dr. (2002) predstavili su pregled korištenja logističke regresije kao statističkog alata u 52 znanstvena članka objavljenih u 3 časopisa iz područja visokog obrazovanja u razdoblju od 1988. do 1999. Zaključuju da više od polovice članaka koristi logističku regresiju u svrhu analize utjecaja varijabli na broj upisanih i diplomiranih studenata. Oko 20% od tog broja članaka analizira vrstu upisanog visokoškolskog programa. Preostali dio članaka koristi logističku regresiju za analizu učinkovitosti studiranja, uspjeha studenata, rang liste institucija, strukture visoko-školskih ustanova i njihovu znanstvenu produktivnost. Hanson i Swann (1993) koriste logističku regresiju za analizu efektivnosti visokoškolskih ustanova uzimajući u obzir uspjeh u studiranju i udio diplomiranih studenata. Zaključuju da udio diplomiranih studenata ovisi o spolu, etničkoj pripadnosti, pohađanju pripremnih programa prije studija, razini akademske i socijalne integracije studenata, financijskim uvjetima studenata. Pyke i Sheridan (1993) koriste logističku regresiju za analizu udjela studenata koji završavaju diplomske i poslijediplomske studije u Kanadi. Uzimaju tri kategorije nezavisnih varijabli: demografske (spol, bračno stanje, godine, državljanstvo), akademske (uspjeh u prethodnim programima, vrsta studija, potrebno vrijeme za završavanje studija) i financijske (stipendije, znanstveno-nastavne potpore). Zaključuju da vjerojatnost završavanja diplomskog studija raste s boljim uspjehom na prethodnim programima, s povećanjem godina studiranja, s povećanjem stipendija, s aktivnošću u nastavnom programu. Vjerojatnost završavanja poslijediplomskog studija raste s porastom financijskih potpora i godina studiranja.

Prednosti i nedostaci logističke regresije

Logistička regresija predstavlja korisnu i često korištenu metodu u raznim analizama. Razlog tome su brojne prednosti koje njezina primjena donosi. Tako se, za razliku od linearne regresije, ne zahtjeva linearan odnos između zavisnih i nezavisnih varijabli. Također se ne zahtjeva normalnost distribucije zavisne varijable. Kod formiranja zavisne varijable jedino je potrebno znati je li se određeni događaj dogodio ili nije, odnosno pripadnost pojedinoj grupi kako bi se formirala zavisna dihotomna varijabla. Također, prednost logističke regresije je i mogućnost izračuna omjera izgleda koji predstavlja omjer između vjerojatnosti u slučaju kada određeni ishod postoji i vjerojatnosti kada on ne postoji.

Kao glavni nedostatak binarne logističke ističe se potreba za većim uzorkom po svakom prediktoru nego kod linearne regresije Peduzzi i dr. (1996) su definirali način izračuna minimalnog broja parametara po varijabli:

$$N = \frac{10k}{p} \quad (5.73)$$

Pritom k predstavlja broj nezavisnih varijabli, a p manju proporciju pozitivne ili negativne zavisne varijable. U slučaju originalnog modela u doktorskoj disertaciji, ukoliko se koristi jedna nezavisna varijabla, s obzirom da je broj DO grupiranih u nepovoljniju grupu 2 jednak 11 (od ukupno 31) (poglavlje 6.3), potreban je uzorak od barem 28 donosioca odluke (5.74)

$$N = \frac{10}{0,3548} = 28,18 \quad (5.73)$$

Ukoliko bi u analizu uvrstili dvije nezavisne varijable, minimalan potreban uzorak u originalnom modelu trebao bi se sastojati od barem 56 DO.

U slučaju alternativnog modela gdje je u manju grupu svrstano 12 DO, potreban je minimalan uzorak od barem 25 DO (5.74)

$$N = \frac{10}{0,387} = 25,84 \quad (5.73)$$

U slučaju alternativnog modela, minimalan uzorak potreban kad bi se koristile 2 nezavisne varijable iznosio bi minimalno 51. Zbog toga je u ovoj doktorskoj disertaciji s obzirom na uzorak od 31 donosioca odluke korištena univarijantna binarna logistička regresija. Kao dodatni nedostatak logističke regresije ističe se teža interpretacija u odnosu na linearnu regresiju.

6. EMPIRIJSKI MODEL VREDNOVANJA RELATIVNE EFIKASNOSTI VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA REPUBLIKE HRVATSKE I DRŽAVA REGIJE

Visokoobrazovne institucije općenito, pa tako i one ekonomskog usmjerenja predstavljaju organizacije čije se poslovanje sastoji od više međusobno povezanih područja djelovanja. Upravo višedimenzionalnost poslovanja i raznolikost aktivnosti koje rezultiraju različitim rezultatima predstavlja problem definiranja njihove kvalitete. S obzirom da profit nije glavni i jedini cilj ovih organizacija, pri definiranju modela vrednovanja nužno je u obzir uzeti sva relevantna područja njihova djelovanja. Vrednovanje samo jednog područja neće dati zadovoljavajuće rezultate jer bi ostale funkcije poslovanja na taj način bile zanemarene i rezultati koji bi se dobili ne bi bila potpuni. Sukladno tome, ovaj model je stvoren u funkciji vrednovanja relativne efikasnosti visokoobrazovnih institucija kroz tri temeljna područja njihova djelovanja (nastavna, znanstvena i međunarodna djelatnost). Vrednovanjem bi se osigurala spoznaja o specifičnim čimbenicima od utjecaja na relativnu efikasnost promatranih visokoobrazovnih institucija ekonomskog obrazovanja. U skladu s time ukazat će se na izvore neefikasnosti te predložiti poboljšanja kojima bi se isti otklonili. Nadalje, temeljem rezultata relativne efikasnosti svakog pojedinog područja promatrane visokoobrazovne institucije podijeliti će se u skupine, odnosno klastere te će se temeljem ključnih čimbenika utvrditi vjerojatnosti prelaska u povoljniji klaster. Model je konstruiran i testiran na primjeru visokoobrazovnih institucija ekonomskog usmjerenja, ali zbog svoje fleksibilnosti bi, uz određene prilagodbe, bio primjenjiv i na visokoobrazovne institucije i drugih usmjerenja.

6.1. DEFINIRANJE I PRETPOSTAVKE MODELA

Postavljanje empirijskog modela vrednovanja relativne efikasnosti visokoobrazovnih institucija ekonomskog usmjerenja polazi od uvažavanja višedimenzionalnog djelovanja promatranih institucija. Model je postavljen u tri faze. **Prva faza** modela konstruirana je na način da su prvo definirana relevantna područja djelatnosti visokoobrazovnih institucija ekonomskog usmjerenja (nastavna, znanstvena i međunarodna djelatnost) te potom inputi i outputi svakog područja. Korištenjem analize omeđivanja podataka (AOMP) unutar svakog područja djelatnosti vrednovana je relativna efikasnost odabranih institucija. Pored vrednovanja svakog područja posebno, postavljen je i model vrednovanja cjelokupnog poslovanja koji

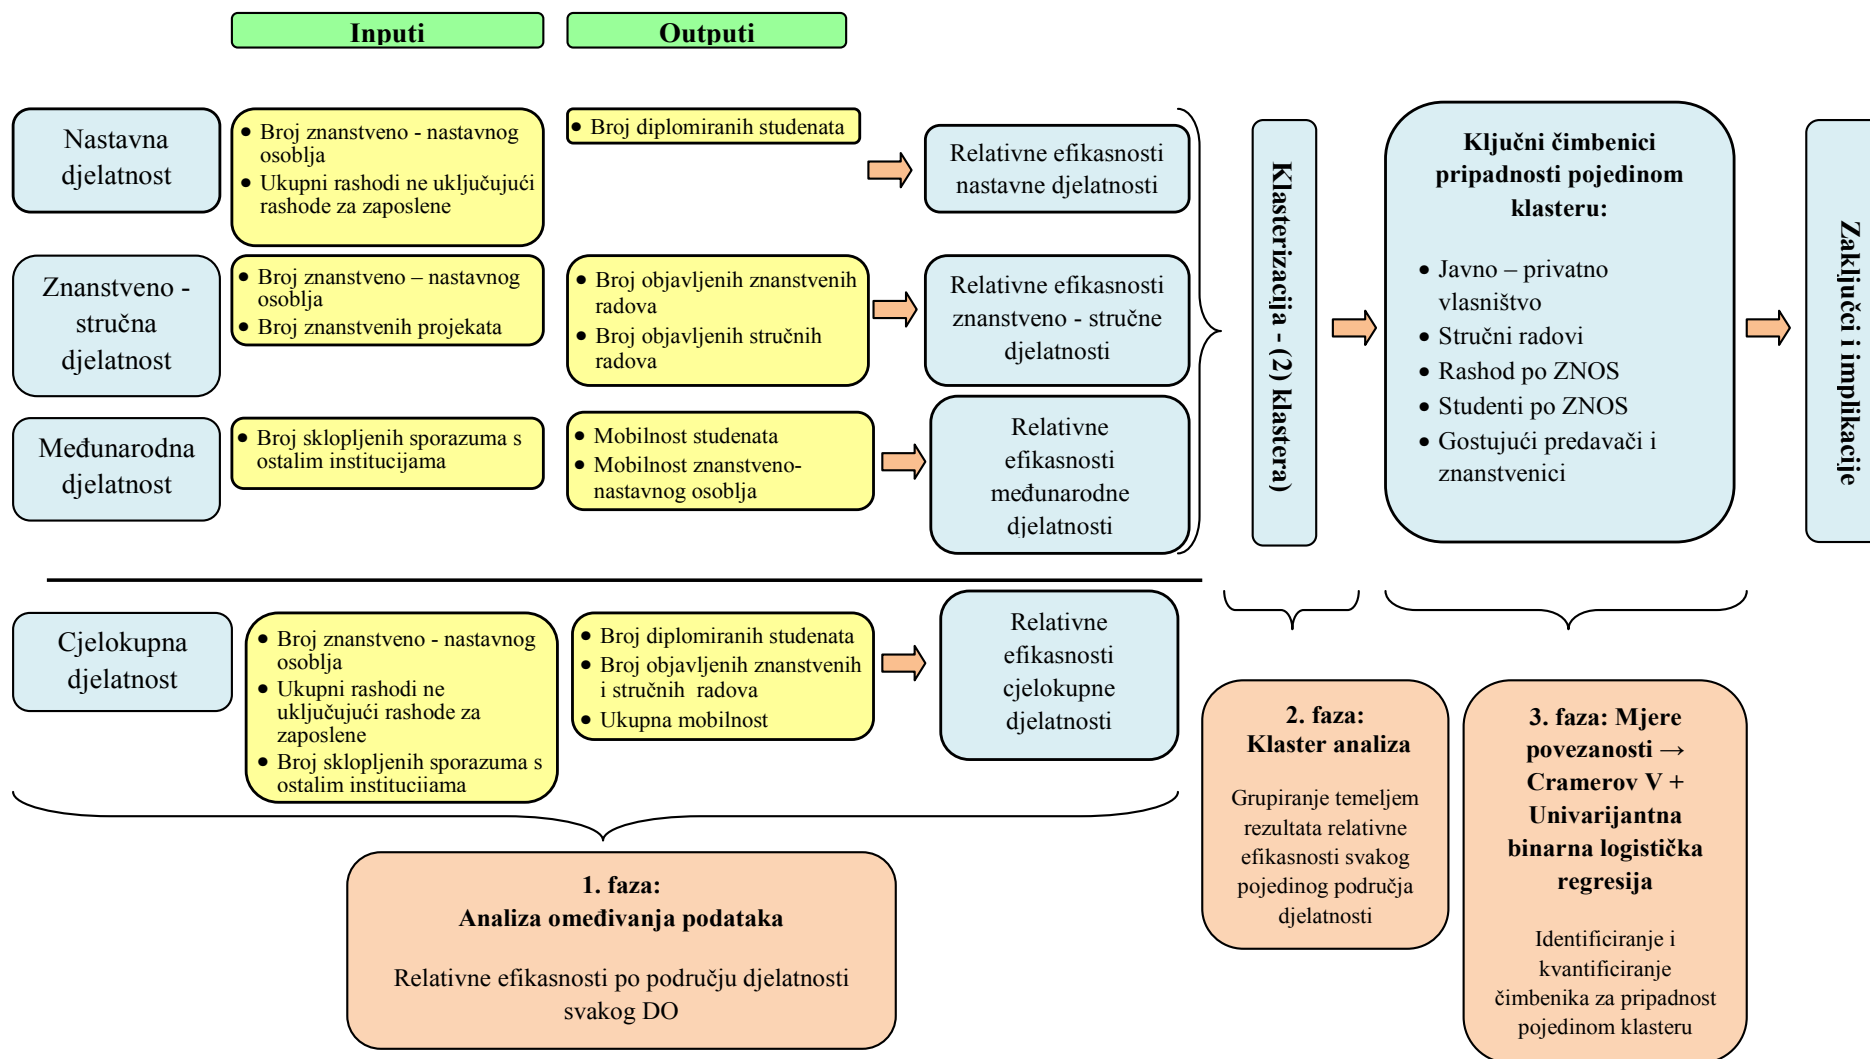
objedinjuje tri istaknuta područja. **Druga faza** vrednovanja polazi od rezultata relativne efikasnosti dobivenih u prvoj istraživačkoj fazi te se sukladno ostvarenim rezultatima provodi hijerarhijska klaster analiza pomoću Ward metode korištenjem Euklidske udaljenosti. Na ovaj način identificirana su dva klastera. Rezultati dobiveni u drugoj fazi polazište su **treće faze** u kojoj se korištenjem univarijantne binarne logističke regresije identificiraju čimbenici od utjecaja na pozicioniranje unutar klastera te se definiraju i kvantificiraju vjerojatnosti prelaska iz jednog u drugi klaster temeljem signifikantnih čimbenika.

Empirijski model vrednovanja prezentiran u ovom radu testiran je na visokoobrazovnim institucijama ekonomskog usmjerenja što ide u prilog jednoj od temeljnih pretpostavki korištenja AOMP-a, a to je homogenost uzorka. Model je testiran na 31 visokoobrazovnoj instituciji ekonomskog usmjerenja u Hrvatskoj, Sloveniji i Bosni i Hercegovini. Iz razloga što je uvjet raspoloživosti podataka bilo osiguranje njihove anonimnosti te zbog toga što cilj doktorske disertacije nije rangiranje DO nego istraživanje odrednica koje utječu na postignutu relativnu efikasnost, institucije na kojima je provedena analiza za potrebe doktorske disertacije biti će šifrirane. S obzirom da je uvjet odabira DO bila diploma iz područja društvenih znanosti, polje ekonomije (institucije su morale održavati minimalno studij(e) na preddiplomskoj razini), u analizu su uključene visokoobrazovne institucije ekonomskog usmjerenja iz sljedećih skupina: fakulteti, odjeli sveučilišta, odjeli veleučilišta te visoke škole. U uzorak su pored javnih uključene i privatne visokoškolske ustanove (Liu, Tsai (2014), Bayraktar, Tatoglu, Zaim (2013)). Studiji iste razine sveučilišnog i stručnog usmjerenja dio su iste razine Europskog, odnosno Hrvatskog kvalifikacijskog okvira (HKO), Slovenskih ravni visokoškolske izobrazbe (RVI) te Kvalifikacijskog okvira u Bosni i Hercegovini (KOBİH) (preddiplomski – razina 6 HKO, KOBİH, 6.2 (RVI); diplomski – razina 7,1 HKO, KOBİH, 7 (RVI)) čime se dodatno potvrđuje opravdanost formiranja uzorka. Dodatni uvjet odabira institucija bio je i početak rada institucije najkasnije u 2008. godini. S obzirom da su institucije promatrane u 2012. godini, kao pretpostavka se je uzeo ciklus od minimalno 3, odnosno 4 godine potrebne za dovršetak preddiplomskog studija. U Hrvatskoj djeluje 31 (MZOS), u Sloveniji 10 (MIZŠ), a u Bosni i Hercegovini 21 (CIP) visoko učilište koje zadovoljava spomenute uvjete. U radu je vrednovano 21 visoko učilište iz Hrvatske (71% ukupne populacije), 7 visokih učilišta iz Slovenije (70% ukupne populacije) te 2 visoka učilišta iz Bosne i Hercegovine (9,5% ukupne populacije). Iz tog razloga se uzorak, iako brojčano malen, smatra reprezentativnim.

Kriteriji za izbor relevantnih područja djelovanja visokoobrazovnih institucija ekonomskog usmjerenja proizlaze iz ciljeva Bolonjske deklaracije te smjernica ESG standarda (eng. The European Standards and Guidelines for Quality Assurance) koji se smatraju zajedničkim skupom europskih načela i referentnih točaka za osiguranje kvalitete visokog obrazovanja. S obzirom da su u izradi ESG standarda pored stručne javnosti (ENQA (eng. European Association for Quality Assurance in Higher Education), te ostale stručne udruge i mreže), bile uključene i krovne organizacije akademske zajednice - Sveučilišta, Institucija visokog obrazovanja, te Studentskih zajednica (EUA (eng. European University Association), EURASHE (eng. European Association of Institutions in Higher Education), ESU (eng. The European Students Union)), smatra se da su odrednice ESG standarda relevantna osnova i znanstveno utemeljeno polazište za odabir temeljnih područja vrednovanja relativne efikasnosti visokoobrazovnih institucija prezentiranih u ovome radu. ESG standardi dizajnirani su na način da budu primjenjivi na sve visokoobrazovne ustanove i agencije za osiguravanje kvalitete u Europskom prostoru visokog obrazovanja, bez obzira na njihovu strukturu, funkciju i veličinu, kao i nacionalni sustav kojemu pripadaju, uvažavajući pritom nacionalni sustav visokog obrazovanja, autonomiju institucija i agencija unutar nacionalnih sustava te specifične zahtjeve različitih akademskih subjekata (ENQA, 2009). Pri odabiru inputa i outputa u ovome modelu kao temeljna podloga korištena je referentna literatura u kojoj se mjerila relativna efikasnost visokoobrazovnih institucija korištenjem AOMP-a.

Ovako postavljen model na novi način pristupa tematici vrednovanja relativne efikasnosti i omogućuje sagledavanje subjekata visokog obrazovanja na širi, sveobuhvatan način. Specifičnosti izabranih institucija, područja (kategorije) vrednovanja poslovanja, indikatori unutar svakog područja, klasterizacija temeljem rezultata relativne efikasnosti različitih područja kao i čimbenici od utjecaja na položaj u određenom klasteru predstavljaju bazu temeljem koje je istraživački model kreiran. Na taj način postavljen model predstavlja originalan praktično - aplikativni znanstveni doprinos ovog istraživanja. Model je prikazan sljedećom shemom.

Shema 17: Prikaz empirijskog modela vrednovanja efikasnosti visokoobrazovanih institucija ekonomskog obrazovanja



Izvor: Autorica

6.2. PRVA FAZA MODELA – VREDNOVANJE RELATIVNE EFIKASNOSTI VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA ANALIZOM OMEĐIVANJA PODATAKA

Temeljne pretpostavke prve faze modela baziraju se na dva osnovna problema. Prvi problem predstavlja definiranje relevantnih područja djelovanja visokoobrazovnih institucija ekonomskog usmjerenja koja su temelj ostvarivanja efikasnog poslovanja. Drugi problem definira se nakon rješavanja prvog problema, a odnosi se na izbor samih indikatora vrednovanja, odnosno na izbor relevantnih inputa (resursa koje koristi organizacija) i outputa (rezultati djelovanja koji moraju biti u skladu s postavljenim ciljevima organizacije) svakog pojedinog područja djelovanja. Uključivanjem u model, odabrani inputi i outputi ostvaruju funkciju pružanja informacije o postignutoj relativnoj efikasnosti promatranih visokoobrazovnih institucija u svakom definiranom području njihova djelovanja.

6.2.1. Odabir inputa i outputa

Odabir inputa i outputa složen je proces u vrednovanju efikasnosti korištenjem analize omeđivanja podataka, a često se spominje i kao najvažniji i nateži dio same analize. Potrebno je odabrati relevantne inpute i outpute koje će pružiti što potpuniju informaciju o efikasnosti pojedinog donosioca odluke te na najbolji način prikazivati vrednovani proces. Takve mjere trebaju dionicima pružiti točne i potpune informacije na temelju kojih oni mogu donositi svoje odluke.

S obzirom da se VOI u svojem poslovanju susreću s velikim brojem ulaznih i izlaznih mjera koje se odnose na različita područja njihova rada, potrebno je u analizu proširiti na više različitih područja djelovanja, koja, iako nisu osnovna djelatnost, itekako su nužna za obavljanje iste. AOMP omogućuje uključivanje i potonjih područja u model. Pri uključivanju inputa i outputa u model mora se uvažavati ograničenje AOMP-a, a to je da zbroj inputa i outputa mora biti minimalno tri puta veći od broja DO uključenih u model. Time se omogućuje da rezultati analize budu čim realniji. Cooper, Seiford, i Tone (2007) naveli su osnovna pravila kojih se je potrebno pridržavati pri izboru inputa i outputa:

- Koriste se isključivo numerički podaci za inpute i outpute, a njihove vrijednosti ograničene su isključivo na pozitivne vrijednosti. Zbog navedenog razloga korištenjem spomenute metode vrijednosti nula (0) potrebno je zamijeniti vrlo niskom pozitivnom vrijednošću koja ne utječe na rezultat;
- Izabrani inputi, outputi i DO trebaju odražavati interes analitičara u komponente koje ući u ocjenu relativne efikasnosti;
- Poželjno je da su razine inputa niže od razina outputa;
- Mjerne jedinice različitih inputa i outputa ne moraju se podudarati (mogu biti različite).

U slučaju da neki inputi ili outputi nedostaju, moguće je koristiti surogatne mjere kako bi svi relevantni faktori bili obuhvaćeni u analizu (Šegota, 2003).

Pri odabiru inputa i outputa u ovome modelu kao temeljna podloga korištena je referentna literatura u kojoj se mjerila efikasnost visokoobrazovnih institucija korištenjem AOMP-a. S obzirom na veliki znanstveni interes stranih istraživača u području efikasnosti visokog obrazovanja, veliki je broj radova koji se bave spomenutom problematikom. Specifičnost outputa visokoobrazovnih institucija je ta da je on u određenoj mjeri nematerijalan zbog čega ga često nije jednostavno mjeriti. U sljedećoj tablici dan je pregled dijela spomenute literature s navedenim imputima i outputima korištenim u istraživanju.

Tablica 19: Pregled inputa i outputa referentne literature

Autor(i)	Godina	Naslov	DO	Input(i)	Output(i)	Zaključci
Arbula, A.	2012	Using data envelopment analysis to evaluate the efficiency of higher education expenditure in Europe	23 zemlje Europe	Potrošnja po studentu (% od BDP p/c)	Populacija upisana na VOI; Stopa zaposlenosti	Istražena je efikasnost korištenja javnih sredstava za visoko obrazovanje u 23 europske zemlje i dani su prijedlozi za poboljšanje efikasnosti neefikasnih DO
Wolszczak-Derlacz, J. i Parteka, A.	2011	Efficiency of European public higher education institutions: a two-stage multicountry approach	259 javne VOI (sveučilišta) iz 7 europskih zemalja-prosjeci na razini zemlje	Broj akademskog osoblja; broj studenata i ukupni prihodi	Broj diploma; broj znanstvenih publikacija	Istražena je efikasnost VOI 7 zemalja Europe. Prisutna je varijabilnost rezultata između zemalja. Kao ključne determinante efikasnosti pokazale su se: veličina VOI, izvori financiranja (vjerojatnost više razine efikasnosti imaju VOI s višim udjelom vanjskih izvora) i spol osoblja (vjerojatnost više razine efikasnosti imaju VOI s višom razinom žena unutar akademskog osoblja)
Aristovnik, A.	2011a	An analysis of the efficiency of education spending in central and eastern Europe	Izabrane zemlje EU i OECD-a + Hrvatska	Potrošnja po studentu (% of BDP p/c)	Nezaposlenost s VO (% od ukupne nezaposlenosti); Radna snaga s VO (% od ukupnog); upisani na VOI (% od ukupnog)	Istražena je relativna efikasnost korištenja javnih sredstava namijenjenih obrazovanju u izabranim zemljama Europe. Nove članice EU pokazale su relativno visoku efikasnost.
Agasisti T. i Pérez-Esparrells C.	2010	Comparing efficiency in a cross-country perspective: the case of Italian and Spanish state universities	57 talijanskih i 46 španjolskih javnih institucija	Broj studenata; broj doktoranada; broj profesora; financijska sredstva	Broj diplomiranih; količina vanjskih resursa povezana s istraživačkim aktivnostima	Poboljšanje uspješnosti (performance) kroz vrijeme u Italiji se dogodilo uslijed velikih tehnoloških promjena, a u Španjolskoj zbog čiste efikasnosti.

Tablica 19 - nastavak

Eckles, J.E.	2010	Evaluating the efficiency of top liberal arts colleges	93 privatna fakulteta humanističkih znanosti u 27 zemalja USA	Troškovi po redovitom upisanom studentu u postotku; Postotak upisanih studenata u prvih 10% klase u srednjoj školi; 25 percentila upisanih studenata prema SAT rezultatima*	Šestogodišnja stopa diplomiranja	Tehničku efikasnost ostvarilo je 18 fakulteta
Kantabutra S. i Tang, J.C.S.	2010	Efficiency analysis of public universities in Thailand	22 javna sveučilišta (18 ovisnih o vladi, a 4 autonomna) - 267 fakulteta	Za TEM **-godišnji operativni budžet; broj akademskog osoblja; broj neakademskog osoblja; Za REM*** - svota internih i eksternih sredstava za istraživanje	Za TEM ** Broj diplomiranih na preddiplomskoj i diplomskoj razini; stopa zaposlenosti; Za REM*** - Broj publikacija u nacionalno i internacionalno referiranim časopisima; Broj ostvarenih doktorskih diploma	Postavljena su dva modela i Tajlandske VOI pokazale su se efikasnije u segmentu obrazovanja (podučavanja) nego u segmentu znanosti (istraživanja)
Tzeremes, N. i Halkos, G.	2010	A DEA approach for measuring university departments' efficiency	16 odjela unutar javnog sveučilišta	Broj akademskog osoblja; broj pomoćnog osoblja (tehničko i administrativno osoblje); broj studenata, ukupni prihod	Broj diplomiranih studenata; broj publikacija	Istražena je efikasnost 16 odjela unutar javnog sveučilišta. Rezultati ukazuju na lošu alokaciju resursa i neefikasno korištenje politike djelovanja odjela.
Johnes, J.	2008	Efficiency and productivity change in the English higher education sector from 1996/97 to 2004/5	112 VOI u Engleskoj	Broj upisanih redovnih dodiplomskih, diplomskih(postgraduate?) studenata; Broj akademskog osoblja; Administrativni troškovi; Troškovi centraliziranih akademskih usluga	Broj dodijeljenih diploma (na svim razinama); Prihod od istraživanja	Nagle promjene u visokom obrazovanju imale su pozitivan učinak na tehnologiju proizvodnje, ali je to ostvareno po cijenu niže tehničke efikasnosti

Tablica 19 - nastavak

Johnes i Yu	2008	Measuring the research performance of Chinese higher education institutions using data envelopment analysis	109 sveučilišta u Kini	Utrošeno vrijeme osoblja; kvaliteta osoblja; upisani poslijediplomci (postgraduate); potrošnja na istraživanja i kapitalne inpute (knjige i prostor u zgradama)	Indeks reputacije VOI; Indeks ukupnog broja publikacija; istraživačke publikacije po akademskom osoblju (produktivnost)	Geografska lokacija pokazala se je važnom (VOI na obali pokazale su se efikasnijima) za razliku od izvora financiranja. Sveobuhvatna sveučilišta pokazala višu prosječnu efikasnost od specijaliziranih institucija
Johnes, J.	2006	Data envelopment analysis and its application to the measurement of efficiency in higher education	100 VOI u Engleskoj na podacima iz 2000/2001	Kvaliteta i kvantiteta preddiplomanada; kvantiteta postdiplomanada; potrošnja na administraciju; iznos plaćenih kamata; deprecijacija	Kvaliteta i kvantiteta preddiplomskih diploma; kvantiteta poslijediplomskih diploma; istraživanje	Istražuje se mogućnost mjerenja efikasnosti u visokom obrazovanju. AOMP se predlaže za korištenje jer omogućava istovremeno korištenje više inputa i outputa.
Abbott, M. i Doucouliagosa, C.	2003	The efficiency of Australian universities: a data envelopment analysis	Australska sveučilišta	Broj akademskog osoblja; broj neakademskog osoblja, potrošnja na sve inpute izuzev inputa rada; vrijednost dugotrajne imovine	Nastavni (ekvivalentni broj redovnih studenata (EFTS omjer); broj upisanih i završenih poslijediplomskih i dodiplomskih studenata) i istraživački output (istraživačke potpore; potrošnja na istraživanje, Research Quantum Allocation****)	Australska sveučilišta pokazala su se efikasna jedna u odnosu na druge, iako kod nekoliko sveučilišta postoji prostora za napredak
Athanassopoulos, A.D. i Shale E.	1997	Assessing the comparative efficiency of higher education institutions in the UK by the means of Data Envelopment Analysis	45 sveučilišta u UK	Broj dodiplomanata, diplomanata (postgraduate?) i akademskog osoblja; aritmetička sredina rezultata upisa A razine u zadnje tri godine; prihod od istraživanja; potrošnja na knjižnicu i računalne usluge	Broj uspješno završenih; Broj nagrađenih diploma; rejtinga istraživanja	Sveučilišta su grupirana u tri osnovne skupine i to: 1) niska troškovna i visoka ishodovna efikasnost, 2) visoka troškovna i niska ishodovna efikasnost 3) visoka troškovna i visoka ishodovna efikasnost

Tablica 19 - nastavak

Beasley, J.E.	1990	Comparing University departments	Odjeli kemije i fizike na sveučilištima u UK	Tekuća potrošnja (većina je za plaće) ; Potrošnja za opremu; Prihod od istraživanja	Broj preddiplomanada; Broj diplomanada; Broj diplomanada koji se bave istraživanjem; Prihod od istraživanja (ovisno o modelu korišten je kao input i kao output); Ocjena - rang istraživanja	Uspoređeni su odjeli fizike i kemije na sveučilištima u UK i dani su prijedlozi za poboljšanje .
---------------	------	----------------------------------	--	---	--	--

*25th percentile of entering students' SAT scores - najbližije državnoj maturi u RH

** TEM (Teaching Efficiency Model) - model nastavne efikasnosti

***REM (Research Efficiency Model)- model istraživačke efikasnosti

**** "Research Quantum in effect" je suma koju je vlada spremna platiti sveučilištu temeljem provedenog istraživanja

Izvor: Kompilacija autorice

Promatranjem prethodnih istraživanja, vidljivo je da su autori vrednovanje efikasnosti oblikovali isključivo na način da su kombinacijom inputa i outputa dobili jednu ocjenu temeljem koje su rangirali DO (Liu, Tsai (2014), Badri, Mohaidat, El Mourad (2014), Wolszczak-Derlacz, Parteka (2011), Aristovnik (2011a,b)). Pojedina istraživanja relativne efikasnosti visokoobrazovnih institucija razlikuju outpute koji se odnose na nastavu te outpute koji se odnose na istraživanja (Sagarra, Agasisti, Mar Molinero (2014), ali unatoč razdvojenom promatranju nisu zabilježeni ozbiljniji naponi za objedinjavanjem tih vrijednosti). Model doktorske disertacije polazi od pretpostavke da visokoobrazovne institucije ne moraju biti jednako efikasne u svim područjima djelovanja tako da je umjesto jedne ocjene nastale korištenjem raznorodnih inputa i outputa bolje efikasnost mjeriti za svako pojedino područje kako bi se dobili potpuniji rezultati. Analizom po pojedinim područjima omogućuje se svakoj visokoobrazovnoj instituciji da izvrši ciljane korekcije točno u području u kojem je neefikasna.

Vrednovanje relativne efikasnosti visokoobrazovanih institucija ekonomskog obrazovanja u ovoj doktorskoj disertaciji koncipirano je u tri različita područja djelatnosti DO (nastavna djelatnost, znanstveno-stručna djelatnost te međunarodna djelatnost). Unutar svakog područja temeljem svjetske literature i dostupnosti podataka identificirani su specifični inputi i outputi. Prilikom definiranja varijabli potrebno je paziti na smjer i visinu korelacija između inputa i outputa. U analizi omeđivanja podataka korelacije moraju imati pozitivan predznak. Test Pearsonove korelacije koristi se kako bi se utvrdila visina i smjer korelacija između varijabli. Vrijednosti od 0,8 na više predstavljaju visoku korelaciju, dok vrijednosti ispod 0,4 predstavljaju nisku korelaciju (Adler, Yazhensky, n.d.). Ukoliko postoje visoke korelacije između jedne varijable inputa i druge (ili više) varijable inputa, odnosno jedne varijable outputa i druge (ili više) varijable outputa pretpostavlja se da taj input/output objašnjavaju korelirane varijable te se on može isključiti iz analize. Ako s druge strane input ima vrlo nisku korelaciju s varijablom (varijablama) outputa i obrnuto, da varijabla outputa ima vrlo nisku korelaciju s varijablom (varijablama) inputa, to ukazuje na činjenicu da varijabla nije prikladna za model (Yang (2009), Sarkis (2002)). Također, prilikom definiranja inputa i outputa u obzir se mora uzeti i broj DO koji mora biti minimalno 3 puta veći od zbroja inputa i outputa. Nakon uvida u korelacije i izbacivanja visokokoreliranih varijabli unutar inputa i outputa te prenisko koreliranih varijabli na relaciji input-output i obrnuto, identificirani su sljedeći inputi i outputi za svako područje djelovanja institucije.

Nastavna djelatnost (ND) smatra se primarnom djelatnošću visokoobrazovnih institucija te je kao takva najčešće bila predmetom vrednovanja. Efikasnost nastavne djelatnosti odnosi se na izvedbu nastave sa svrhom pružanja znanja na preddiplomskoj i diplomskoj razini. Najbitniji dionici nastavnog procesa su nastavno osoblje i studenti. Ovo područje predmet je unutarnjeg osiguranja kvalitete u ustanovama visokog obrazovanja prema ESG standardima. U istraživanju je relativna efikasnost DO u ovom području definirana sljedećim varijablama.

Inputi:

1. Broj znanstveno-nastavnog osoblja (ZNOS) – jedan je od najbitnijih inputa nastavnog rada i kao takav visoko zastupljen u svjetskoj literaturi (Johnes, 2006, Tse Kuah, Yew Wong, 2011, Abd Aziz, Mohd Janor, Mahadi (2013)). Ova mjera uzima u obzir svo nastavno osoblje uključeno u nastavni proces (Flegg i dr. (2003), Agasisti, Pérez-Esparrells (2010), Tzeremes, Halkos (2010), Abbott, Doucauliagos (2003), García-Aracil, Palomares-Montero (2008), Liu, Tsai (2014)).
2. Ukupni rashodi ne uključujući rashode za zaposlene (RASH) – S obzirom da je input rashoda za zaposlene visoko koreliran s brojem ZNOS, a rashodi poslovanja predstavljaju bitan čimbenik nesmetanog odvijanja osnovne djelatnosti visokoobrazovnih institucija, kao input su uzeti rashodi umanjeni za rashode za zaposlene (Abbott, Doucauliagos (2003), Førsund, Kalhagen (1999), McMillan, Datta (1998), Coelli (1996). Ukupni rashodi ne uključujući rashode za zaposlene izraženi su u valuti Republike Hrvatske, Hrvatskoj kuni.

Output:

1. Broj diplomiranih studenata (STUD)– Ova varijabla predstavlja karakterističan output visokog obrazovanja (Tzeremes, Halkos (2010), Abd Aziz, Mohd Janor, Mahadi (2013), Sagarra, Agasisti, Mar Molinero (2014), García-Aracil, Palomares-Montero (2008)). U obzir su uzeti studenti koji su diplomirali na preddiplomskom i diplomskom studiju.

Znanstveno-stručna djelatnost (ZD) se pored nastavne djelatnosti smatra jednom od ključnih područja djelovanja visokoobrazovnih institucija. Iako neki DO ne daju prioritet znanstvenoj djelatnosti (tu se prije svega misli na visoke škole), preporuka AZVO-a pri postupcima reakreditacije kao jednu od najbitnijih radnji ističe poticanje upravo te vrste djelatnosti. Zbog toga se smatra opravdanim i njih uključiti u proces vrednovanja. Pri vrednovanju efikasnosti DO u ovom području korištene su sljedeće varijable:

Inputi:

1. Broj znanstveno-nastavnog osoblja (ZNOS) – ovaj input je zajednički nastavnoj i znanstveno-stručnoj djelatnosti jer je najčešće isto osoblje uključeno i u proces nastave i u proces znanstveno-stručne djelatnosti.
2. Broj znanstvenih projekata na Instituciji (ZNPROJ) – predstavlja broj domaćih i međunarodnih znanstvenih projekata kojima je nositelj određena visokoobrazovna institucija. S obzirom da se znanstveni i stručni radovi vežu uz znanstvene projekte na instituciji te je cilj da postojeći projekti urode što većim brojem znanstvenih i stručnih radova, ova varijabla je korištena kao input poslovanja.

Outputi:

1. Broj objavljenih znanstvenih radova (ZNRAD) – Ova varijabla predstavlja najbitniji output znanstveno-stručne djelatnosti (Wolszczak-Derlacz, Parteka (2011), Sagarra, Agasisti, Mar Molinero (2014), García-Aracil, Palomares-Montero (2008)). Broj objavljenih znanstvenih radova uvjet je vanjskog vrednovanja znanstveno-nastavne djelatnosti kao i napredovanja u zvanje znanstveno-nastavnog osoblja.
2. Broj objavljenih stručnih radova (STRAD) – S obzirom da se znanstveni i stručni radovi ne vrednuju jednako pri izboru u zvanje, ove kategorije se promatraju razdvojeno.

Međunarodna djelatnost (MD) je postala vrlo bitan segment poslovanja visokoobrazovnih institucija. Stvaranje zajedničkog obrazovnog i znanstvenog prostora jedna je od odrednica europske politike. To podrazumijeva “*slobodno kretanje studenata, profesora, znanstvenika i istraživača u području visokog obrazovanja i znanosti*” (MZOS, n.d.). Promicanje mobilnosti jedan je od ciljeva bolonjske deklaracije i bolonjskog procesa. Zbog navedenog je ovo područje uzeto kao jedno od ključnih za analizu.

Input:

1. Broj suradnji s ostalim institucijama (SURAD) – potpisivanjem bolonjske deklaracije i isticanjem mobilnosti kao jedne od ključnih odrednica kvalitete institucije, visokoobrazovne institucije su počele potpisivati bilateralne i multilaterarne ugovore s drugim institucijama sa svrhom jačanja mobilnosti. Ova varijabla predstavlja input područja međunarodne aktivnosti iz razloga jer ona visokoobrazovnim institucijama služi samo kao institucionalni okvir međusobne suradnje. Output predstavlja sam rezultat potpisanih ugovora, a to je broj dolaznih i odlaznih studenata i znanstveno-nastavnog osoblja.

Outputi:

1. Mobilnost studenata (MOBS) – Odnosi se na broj studenata koji su proveli neko vrijeme na drugoj instituciji ili su došli na promatranu instituciju. Broj odlaznih studenata daje informaciju o naporima institucije da pošalje studente na razmjenu dok broj dolaznih studenata daje informaciju o prepoznatljivosti institucije izvan vlastitih okvira. S obzirom na nedostatak podataka za sve DO u vidu točnog vremena provedenog na razmjeni, ta dimenzija nije uvažena.
2. Mobilnost znanstveno-nastavnog osoblja (MOBZO) – Ova varijabla predstavlja broj matičnog znanstveno-nastavnog osoblja koji je proveo određeno vrijeme na drugoj instituciji i broj tuđeg znanstveno-nastavnog osoblja koji je proveo određeno vrijeme na promatranoj instituciji u vidu održavanja nastave, edukacije ili sudjelovanja u znanstveno istraživačkom radu. Također, s obzirom na ograničenje podataka, vrijeme boravka nije uzimano kao faktor vrednovanja.

Cjelokupna djelatnost (CD) predstavlja model koji objedinjava inpute i outpute posebnih područja djelovanja te daje skupnu ocjenu relativne efikasnosti ne uvažavajući posebnosti poslovanja. Kod izbora inputa i outputa, zbog visokih korelacija koje su bile prisutne između inputa te između outputa, pojedine varijable su morale biti izbačene dok su druge modificirane te kao takve predstavljaju surogatne mjere.

Inputi:

1. Broj znanstveno-nastavnog osoblja (ZNOS)
2. Ukupni rashodi ne uključujući rashode za zaposlene (RASH)
3. Broj suradnji s ostalim institucijama (SURAD)

Outputi:

1. Broj diplomiranih studenata (DIPL)
2. Mobilnost (MOBIL)– Ukupna mobilnost studenata i znanstveno-nastavnog osoblja
3. Broj objavljenih znanstvenih i stručnih radova (ZSRAD)– Ovaj output dobiven je zbrojem objavljenih znanstvenih i stručnih radova pri čemu je znanstvenim radovima pridodana težina 1, a stručnim 0,5.

Metoda i model imaju i svojevrsna ograničenja. Prije svega, ona se očituju u činjenici da na ovaj način dobiveni rezultati daju informaciju o relativnoj efikasnosti promatranih DO, ali ne i o njihovoj apsolutnoj efikasnosti. Iz tog razloga dodavanje ili oduzimanje DO imalo bi utjecaj na dobivene rezultate. Isto se odnosi i na odabir inputa i outputa čiji izbor ima značajan utjecaj

na same rezultate. Zbog djelomično agregiranih podataka za pojedine donosioce odluke, za iste se vršila procjena financijskih parametara temeljem broja studenata kao ključa rasporeda. Neraspoloživost pojedinih podataka predstavlja ograničenje i u izboru inputa i outputa tako da, u slučaju buduće raspoloživosti dodatnih relevantnih podataka, predlaže se dopuna modela istima.

6.2.2. Testiranje modela vrednovanja relativne efikasnosti javnih ekonomskih fakulteta primjenom analize omeđivanja podataka

Nakon odabira inputa i outputa i teorijskog postavljanja modela slijedi njegovo testiranje. Vrednovanje visokoobrazovnih institucija ekonomskog usmjerenja vršeno je na podacima prikupljenim za 2012. godinu, odnosno 2011./2012. akademsku godinu. U analizi je korišten softverski paket DEA Solver Pro 11.0, a podaci za inpute i outpute prikupljeni su putem upitnika doktorandice, od Ministarstva financija Republike Hrvatske, Amadeus baze, Fin info portala, Izvješća stručnog povjerenstva AZVO-a o reakreditaciji visokih učilišta, samoevaluacija, odnosno unutarnjih prosudba visokih učilišta, strategija visokih učilišta, plana rada visokih učilišta, CROSBI baze, SICRIS baze te službenih internetskih stranica promatranih subjekata. Deskriptivna statistika inputa i outputa i koeficijenti korelacije za svaki model prikazani su u nastavku.

Nastavna djelatnost

Tablica 20: Deskriptivna statistika inputa i outputa za model nastavna djelatnost

	ZNOS	RASH	DIPL
Max	238	52 212 973	2428
Min	10	913 214,8	17
Average	52,5806	11 178 998	408,742
SD	44,7306	11 460 816	523,306

Izvor: Izračun autorice

Tablica 21: Koeficijenti korelacije inputa i outputa za model nastavna djelatnost

	ZNOS	RASH	DIPL
ZNOS	1	0,688584	0,91349
RASH	0,68858	1	0,6518
DIPL	0,91349	0,651795	1

Izvor: Izračun autorice

Znanstvena djelatnost

Tablica 22: Deskriptivna statistika inputa i outputa za model znanstveno-stručna djelatnost

	ZNOS	ZPROJ	ZNRAD	STRAD
Max	238	32	472	186
Min	10	0	0	0
Average	52,5806	4,6129	68,1935	20,6774
SD	44,7306	7,43435	100,86	35,3511

Izvor: Izračun autorice

Tablica 23: Koeficijenti korelacije inputa i outputa za model znanstveno-stručna djelatnost

	ZNOS	ZPROJ	ZNRAD	STRAD
ZNOS	1	0,80232	0,85921	0,65784
ZPROJ	0,80232	1	0,921	0,67681
ZRAD	0,85921	0,921	1	0,76008
SRAD	0,65784	0,67681	0,76008	1

Izvor: Izračun autorice

Korelacija između input varijabli ZNOS i ZPROJ je na gornjoj rubnoj vrijednosti, ali zbog važnosti su oba inputa uzeta u obzir.

Međunarodna djelatnost

Tablica 24: Deskriptivna statistika inputa i outputa za model međunarodna djelatnost

	SURAD	MOBILS	MOBILZN
Max	96	548	76
Min	1	0	0
Average	27,7419	45,871	16,8065
SD	24,5803	100,205	17,7081

Izvor: Izračun autorice

Tablica 25: Koeficijenti korelacije inputa i outputa za model međunarodna djelatnost

	SURAD	MOBILS	MOBILZN
SURAD	1	0,44254	0,60478
Mob S	0,44254	1	0,46223
Mob ZO	0,60478	0,46223	1

Izvor: Izračun autorice

Cjelokupna djelatnost

Tablica 26: Deskriptivna statistika inputa i outputa za model cjelokupna djelatnost

	ZNOS	RASH	SURAD	DIPL	ZSRAD	MOBIL
Max	238	52 212 973	96	2428	559	584
Min	10	913 214,8	1	17	0	0
Average	52,5806	11 178 998	27,74194	408,742	88,871	62,7742
SD	44,7306	11 460 816	24,58031	523,306	129,779	109,469

Izvor: Izračun autorice

Tablica 27: Koeficijenti korelacije inputa i outputa za model cjelokupna djelatnost

	ZNOS	RASH	SURAD	DIPL	ZSRAD	MOBIL
ZNOS	1	0,688584	0,542293	0,91349	0,84694	0,55879
RASH	0,68858	1	0,664125	0,6518	0,68599	0,80437
SURAD	0,54229	0,664125	1	0,55637	0,6109	0,5021
DIPL	0,91349	0,651795	0,556371	1	0,78751	0,50531
ZSRAD	0,84694	0,685993	0,610897	0,78751	1	0,78989
MOBIL	0,55879	0,804374	0,502099	0,50531	0,78989	1

Izvor: Izračun autorice

Nakon odabira inputa i outputa i teorijskog postavljanja modela slijedi njegovo testiranje. Kako bi se provelo testiranje modela, za početak je važno definirati još dvije bitne odrednice. Jedna se odnosi izbor modela (CCR – (Charnes, Cooper i Rhodes model) ili BCC (Banker, Charnes i Cooper model)), a druga na orijentaciju modela (input ili output orijentiran model). Obje odrednice definiraju se sukladno karakteristikama promatranih DO te podacima koji su raspoloživi u procesu analize.

Odluka hoće li biti korišten CCR ili BCC model ovisi o prinosu promatranog procesa. Ukoliko su prinosi konstantni (eng. constant returns to scale CRS) koristi se CCR model, a ukoliko su varijabilni (eng. variable returns to scale VRS), koristi se BCC model. Konstantni prinosi pretpostavljaju da povećanje inputa dovodi do proporcionalnog povećanja outputa, dok varijabilni prinosi pretpostavljaju da povećanje inputa ne dovodi do proporcionalnog povećanja outputa već ono može biti veće ili manje od rasta inputa. Kako bi se točno odredio tip modela koji će se koristiti, preporučeno je napraviti analizu s oba tipa modela te potom usporedbom rezultata sa sigurnošću izabrati ispravan. Ukoliko su rezultati slični, preporučeno je koristiti CCR model (najvjerojatnije nema efekta obujma), a ukoliko su rezultati različiti uputno je koristiti BCC model (zbog vjerojatnog postojanja efekta obujma). Odabir orijentacije modela isključivo se bira temeljem ciljeva koje promatrani DO žele postići. S obzirom da

visokoobrazovne institucije imaju za cilj da s postojećim sredstvima maksimiziraju svoje outpute, korišten je outputu usmjeren model. On pretpostavlja efikasnost kao ostvarivanje maksimalnog outputa uz korištenje postojećih inputa. Također, ograničenje financijskih sredstava za potrebe visokog obrazovanja dovodi vodstvo visokoobrazovnih institucija u poziciju da, kako bi poslovanje učinili efikasnijim, korištenjem postojećih inputa ulože napore kako bi povećali output. Ovu odluku podupire referentna literatura koja upućuje upravo na ovu orijentaciju (Arbula, 2012; Aristovnik, 2011a,b; Johnes, Bradley, Little, 2012; Johnes, Yu, 2008; Tóth, 2009).

Tablica 28: Rezultati relativne efikasnosti primjenom CCR i BCC modela s output orijentacijom za sve modele

	Nastavna djelatnost		Znanstveno-stručna djelatnost		Međunarodna djelatnost		Cjelokupno poslovanje	
	CCR	BCC	CCR	BCC	CCR	BCC	CCR	BCC
Broj efikasnih DO	1	6	10	11	2	5	11	15
Broj neefikasnih DO	30	25	21	20	29	26	22	16
Prosječan rezultat	0,4244	0,5958	0,5599	0,5788	0,2847	0,4358	0,752	0,7844
Maksimalan rezultat	1	1	1	1	1	1	1	1
Minimalan rezultat	0,0724	0,0767	0,0001	0,0001	0,0001	0,0001	0,2981	0,3106

Izvor: Izračun autorice

Usporedbom rezultata relativne efikasnosti 31 visokoobrazovne institucije ekonomskog usmjerenja korištenjem osnovnih modela s konstantnim i varijabilnim prinosom na opseg djelovanja vidljivo je značajno odstupanje u broju efikasnih ($\theta^* = 1$) DO u području nastavne djelatnosti, međunarodne djelatnosti te u cjelokupnoj djelatnosti zbog čega je u navedenim područjima korišten BCC model koji podrazumijeva varijabilne prinose na opseg poslovanja. U području znanstveno-stručne djelatnosti odstupanje je minimalno (CCR model identificira 10, a BCC 11 relativno efikasnoh DO) zbog čega je korišten CCR model koji podrazumijeva konstantne prinose na opseg poslovanja .

Dobivene vrijednosti ukazuju na izrazitu nekonzistentnost u rezultatima između različitih područja. Prosječno najviši rezultat zabilježen je kod cjelokupne djelatnosti što se može

objasniti da visokoobrazovne institucije u prosjeku nisu jednako efikasne u svakom području djelovanja, nego relativno efikasnijim rezultatima poslovanja jednog područja supstituiraju se relativno manje efikasni rezultati drugog područja poslovanja. Zbog toga je vrednovanje po segmentima poslovanja je opravdano jer daje točniju sliku poslovanja. Na sljedećoj tablici dani su pojedinačni rezultati relativne efikasnosti svakog DO po pojedinom području.

Tablica 29: Rezultati relativne efikasnosti visokoobrazovnih institucija ekonomskog usmjerenja po različitim modelima

DO	ND - BCC	Rang	ZD - CCR	Rang	MD - BCC	Rang	CD - BCC	Rang
DO1	0,9154	11	0,452	16	0,2534	20	1	1
DO2	1	1	0,4677	15	0,1976	22	1	1
DO3	0,4322	19	0,5469	14	0,3321	18	0,7746	18
DO4	1	1	0,6523	12	0,8148	7	1	1
DO5	0,9469	10	0,3248	23	0,1893	23	1	1
DO6	0,2262	25	1	1	0,1845	24	0,3767	29
DO7	0,0767	31	0,3557	21	0,1023	27	0,3106	31
DO8	0,2204	26	0,2393	24	0,0001	31	0,4489	28
DO9	0,3434	22	0,2187	25	0,0824	28	0,4977	27
DO10	0,3328	23	1	1	0,392	13	0,8565	16
DO11	0,2103	27	0,0001	30	0,269	19	0,3142	30
DO12	0,7067	13	0,6332	13	0,6622	8	1	1
DO13	0,4743	18	0,4516	17	0,0383	29	0,5242	25
DO14	0,2684	24	0,0001	30	0,467	12	0,6219	22
DO15	0,9999	7	0,1012	28	1	1	1	1
DO16	1	1	1	1	0,3819	14	1	1
DO17	1	1	1	1	0,2045	21	1	1
DO18	0,6798	14	0,8701	11	0,3777	15	0,7264	20
DO19	1	1	0,0861	29	0,0255	30	1	1
DO20	0,996	8	1	1	1	1	1	1
DO21	0,5258	17	0,1918	27	0,3624	16	0,5773	23
DO22	0,5568	16	0,1949	26	0,9073	6	1	1
DO23	0,9591	9	1	1	0,4827	11	1	1
DO24	0,3597	20	1	1	0,4868	10	0,7555	19
DO25	0,7943	12	1	1	1	1	1	1
DO26	0,1819	29	0,3616	20	0,3421	17	0,5476	24
DO27	0,1883	28	1	1	1	1	1	1
DO28	0,3449	21	0,4148	19	0,1397	26	0,5219	26
DO29	1	1	1	1	0,6594	9	1	1
DO30	0,151	30	0,4412	18	0,1553	25	0,6655	21
DO31	0,5787	15	0,3518	22	1	1	0,7962	17

Izvor: Izračun autorice

Promatranjem rezultata relativne efikasnosti po pojedinom modelu za svakog DO zasebno, uočljivo je kako niti jedan DO nije relativno efikasan u svim područjima vrednovanja ($\exists \theta^*_i < 1$; $i=ND, ZD, MD$). Također je uočljivo kako su pojedini DO koji su relativno neefikasni ($\theta^* < 1$) u svim zasebnim područjima vrednovanja ocijenjeni kao relativno efikasni ($\theta^* = 1$) u cjelokupnoj djelatnosti. Razlog tome je nova granica relativne efikasnosti koja se dobije novom kombinacijom inputa i outputa. Ovakvi rezultati daju potpuno novu perspektivu na vrednovanje relativne efikasnosti kompleksnih DO poput visokoobrazovnih institucija. Isti ukazuju na važnost vrednovanja svakog područja zasebno kako bi se dobio točniji uvid u rezultate relativne efikasnosti te kako bi se pružile usmjerenije preporuke za unaprjeđenje.

Nakon ocjenjivanja relativne efikasnosti visokoobrazovnih institucija ekonomskog usmjerenja, kako bi se utvrdili relativno efikasni DO čijim rezultatom poslovanja bi se svaki neefikasni DO mogao voditi, ispitat će se frekvencije pojavljivanja relativno efikasnih DO u referentnom skupu. Čim je frekvencija zastupljenosti relativno efikasnih DO veća, veća je vjerojatnost da je riječ o DO koji može pružiti primjer dobre prakse. Referentni skup predstavlja relativno efikasne DO s kojima se uspoređuju relativno neefikasni DO. Drugim riječima, relativno neefikasnim DO se pridružuju relativno efikasni DO iz referentnog skupa koji služe kao referentni subjekti u koje se relativno neefikasni subjekti trebaju ugledati kako bi svoje poslovanje učinili efikasnijim. Bitno je napomenuti kako referentni skup relativno neefikasnih visokoobrazovnih institucija čine relativno efikasne visokoobrazovne institucije koje imaju najbližnju input/output orijentaciju relativno neefikasnoj visokoobrazovnoj instituciji. U sljedećoj tablici prikazana je učestalost pojavljivanja relativno efikasnih DO u referentnom skupu te su predstavljeni članovi referentnog skupova relativno neefikasnih visokoobrazovnih institucija ekonomskog usmjerenja za svaki od četiri modela.

Tablica 30: Učestalost pojavljivanja relativno efikasnih visokoobrazovnih institucija u referentnom skupu i članovi referentnog skupa po svakom modelu

DO	Nastavna djelatnost		Znanstvena djelatnost		Međunarodna djelatnost		Cjelokupna djelatnost	
	Frekv.	referentni skup (λ)	Frekv.	referentni skup (λ)	Frekv.	referentni skup (λ)	Frekv.	referentni skup (λ)
DO1		DO2 , DO29		DO27		DO27, DO31	5	DO1
DO2	24	DO2		DO23, DO27		DO25, DO27	8	DO2
DO3		DO2, DO4		DO24, DO27		DO25, DO27, DO31		DO2, DO4, DO20, DO27
DO4	8	DO4		DO24, DO27		DO25, DO27	6	DO4
DO5		DO2, DO4		DO24, DO27		DO25, DO27, DO31	2	DO5
DO6		DO2, DO29	8	DO6		DO15, DO25 , DO31		DO1, DO20, DO23, DO25
DO7		DO2, DO29		DO24, DO27		DO27, DO31		DO23, DO27, DO29
DO8		DO2 , DO19, DO29		DO16, DO24, DO29		DO15, DO20		DO20, DO22, DO25
DO9		DO2, DO4		DO6, DO10		DO15, DO25, DO31		DO2, DO4, DO5, DO22
DO10		DO2, DO29	7	DO10		DO25, DO27		DO25 , DO29
DO11		DO2, DO29		DO10		DO15, DO25 , DO31		DO1, DO19, DO22, DO25
DO12		DO15, DO17		DO6, DO10, DO20		DO15, DO25, DO31	2	DO12
DO13		DO2, DO17		DO6, DO17		DO20, DO25		DO2, DO4, DO20, DO22
DO14		DO2, DO17		DO10 , DO16		DO15, DO20, DO25		DO15, DO20, DO25
DO15	2	DO15		DO6, DO17, DO20	15	DO15	4	DO15
DO16	1	DO16	5	DO16		DO15, DO20, DO25	2	DO16
DO17	9	DO17	4	DO17		DO15, DO20	2	DO17
DO18		DO2, DO17		DO6, DO17		DO15, DO20, DO25		DO2 , DO12, DO15, DO20,
DO19	5	DO19		DO24, DO27		DO20, DO25	3	DO19
DO20		DO2, DO17, DO19	3	DO20	9	DO20	8	DO20
DO21		DO2, DO29		DO6, DO10		DO27, DO31		DO1, DO19 , DO23, DO25
DO22		DO2, DO4		DO6, DO10		DO15, DO20, DO25	6	DO22
DO23		DO2, DO29	2	DO23		DO25, DO27, DO3	5	DO23
DO24		DO2, DO4	11	DO24		DO27		DO2, DO23, DO25, DO27
DO25		DO2, DO4	1	DO25	20	DO25	10	DO25

Tablica 30 - nastavak

DO26		DO2, DO19, DO29		DO24, DO27		DO15, DO25, DO31		DO2, DO15, DO25, DO27, DO29
DO27		DO2, DO17	10	DO27	11	DO27	8	DO27
DO28		DO2, DO17		DO16, DO24, DO29		DO15, DO31		DO2, DO4, DO20, DO27
DO29	9	DO29	5	DO29		DO15, DO25, DO31	4	DO29
DO30		DO2, DO17, DO19		DO24, DO27, DO29		DO15, DO25, DO31		DO16, DO17, DO27
DO31		DO2, DO4		DO16, DO24, DO29	15	DO31		DO1, DO4, DO22, DO25

Izvor: Izračun autorice

Valja napomenuti kako se DO15 u modelu Nastavna djelatnost, iako nije ocijenjen kao relativno efikasan ($\theta^* = 0,9999$), zbog izuzetne blizine granici relativne efikasnosti ($\theta^* = 1$), ipak pojavljuje kao dio referentnog skupa.

S obzirom da je referentni skup relativno neefikasnih DO sačinjen od relativno efikasnih DO čija je input/output orijentacija najbližnja neefikasnom DO, ova informacija je vrlo vrijedna jer pruža neefikasnim DO uporište za postavljanje realnih ciljeva za poboljšanje efikasnosti.

Analiza omeđivanja podataka pored vrednovanja relativne efikasnosti omogućuje identificiranje samih izvora neefikasnosti te njihovu kvantifikaciju. Drugim riječima, ona omogućuje svakom neefikasnom DO da određenim poboljšanjima izvrši projekciju poslovanja na granicu efikasnosti čime se pruža vrlo bitna informacija o potencijalnim poboljšanjima koja neefikasan DO može napraviti kako bi postao relativno efikasan. Upravo ovaj korak predstavlja ključnu informaciju budući da daje konkretne vrijednosti koje DO trebaju ostvariti kako bi poboljšali svoju relativnu efikasnost te pruža smjernice za formiranje i oblikovanje realnih ciljeva.

S obzirom da su podaci o potencijalnim poboljšanjima s obzirom na četiri različita modela vrlo opsežni, u nastavku je prikazana tablica s prosječnim poboljšanjima u apsolutnim iznosima za svaki output ovisno o modelu. Kompletna tablica s podacima o poboljšanjima po pojedinim donosiocima odluke dana je u prilogu 1.

Tablica 31: Podaci o prosječnim poboljšanjima (projekcijama) za relativno neefikasne visokoobrazovne institucije

	DIPL		SRAD		ZRAD		Mob S		Mob ZO		Mobilnos		DIPL		ZSRAD	
	Data	Proj.	Data	Proj.	Data	Proj.	Data	Proj.	Data	Proj.	Data	Proj.	Data	Proj.	Data	Proj.
Prosjek	408,7	685,8	20,6	32,6	68,1	110,	45,9	94,0	16,8	35,8	62,8	80,8	408,7	496,0	88,9	113,7

Izvor: Izračun autorice

U nastavku će biti prikazana potencijalna poboljšanja za pojedine DO.

Tablica 32: Podaci o potencijalnim poboljšanjima za DO25 u modelu Nastavna djelatnost

	Rezultat	DIPL		
		Data	Proj.	Razlika(%)
DO25	0,7943	1339	1686	25,9

Izvor: Izračun autorice

DO25 ocijenjen je relativno neefikasnim samo u modelu Nastavna djelatnost. Kako bi postao relativno efikasan, broj diplomiranih studenata trebao bi biti za 25,9% viši.

Tablica 33: Podaci o potencijalnim poboljšanjima za DO12 u modelima Nastavna djelatnost, Znanstveno-stručna djelatnost i Međunarodna djelatnost

	Rezultat	Nastavna djelatnost			Rezultat	Znanstveno-stručna djelatnost					
		DIPL				SRAD			ZRAD		
		Dana	Proj.	Razl.(%)		Data	Proj.	Razl.(%)	Data	Proj.	Razl.(%)
DO12	0,7067	19	26,9	41,5	0,6332	14	22,1	57,923	12	18,9	57,923

	Međunarodna djelatnost						
	Mob S			Mob ZO			
	Rezult	Data	Projection	Razl.(%)	Data	Projection	Razl.(%)
	0,6622	15	22,7	51,0	20	30,2	51,0

Izvor: Izračun autorice

DO12 ocijenjen je relativno efikasnim prema modelu Cjelokupna djelatnost, ali podjelom na pojedinačne modele identificiraju se izvori neefikasnosti. Kako bi u modelu Nastavna djelatnost DO12 iz slabo efikasnih DO prešao u skupinu relativno efikasnih DO treba broj diplomiranih studenata povećati za 41,5%. U modelu znanstveno-stručna djelatnost, broj objavljenih znanstvenih i stručnih radova treba povećati za 57,923%, dok u modelu Međunarodna djelatnost mobilnost studenata i znanstvenog osoblja treba povećati za 51% kako bi došao na granicu relativne efikasnosti.

Iako analiza omeđivanja podataka pruža vrijedne informacije, ona nam ne pruža mogućnost statističkog zaključivanja. Kako bi se došlo do statistički značajnih zaključaka korisnih donositeljima obrazovnih politika, pristupa se drugoj i trećoj fazi vrednovanja.


6.3. DRUGA FAZA MODELA – GRUPIRANJE DONOSIOCA ODLUKE PRIMJENOM KLASTER ANALIZE

Klaster analiza je statistička metoda kojom se identificiraju i klasificiraju grupe unutar skupine različitih objekata (DO). Koristi se za kategorizaciju jedinica koje se analiziraju temeljem njihove sličnosti ili različitosti promatranih obilježja. To se vrši temeljem definiranja matrice udaljenosti koja utvrđuje poveznice između različitih objekata temeljem kojih se oni najbliži povezuju u grupe. U radu je korištena Euklidska udaljenost između vektora $x=(x_1,x_2,\dots,x_p)$ i $y=(y_1,y_2,\dots,y_p)$, standardna mjera klasterizacije koja predstavlja najmanju udaljenost između dvije točke u jednom prostoru. Pri odabiru metoda klasterizacije najčešće se koriste hijerarhijske i nehijerarhijske metode. U ovom radu koristit će se hijerarhijska aglomerativna klaster analiza, koja polazi od pojedinih objekata (u ovom slučaju visokoobrazovnih institucija ekonomskog usmjerenja) kao početnih klastera te svakim sljedećim korakom spaja po dva najbliža klastera. Kod hijerarhijske klaster analize broj koraka (klasterskih rješenja) je $k-1$ gdje je k broj objekata. S obzirom da se u doktorskoj disertaciji analiza provela na 31 visokoobrazovnoj instituciji ekonomskog usmjerenja, klasterizacija će se vršiti u 30 koraka.

Klaster analizom visokoobrazovne institucije klasificirane su u skupine sukladno ostvarenim razinama relativne efikasnosti iz područja nastavnog rada, znanstveno-stručnog rada i međunarodne suradnje. U analizi je korišten softverski paket Stata/IC 13.0. Kako bi se identificirali klasteri, Wardovom metodom se za svaki klaster izračunaju aritmetičke sredine

svake pojedine varijable te se potom za svaku visokoobrazovnu instituciju računa kvadrirana euklidska udaljenost do aritmetičke sredine klastera. Ove udaljenosti se potom zbrajaju za sve članove klastera. Klasteri se potom formiraju na način da se spajaju oni klasteri kojima je najmanja ukupna suma spomenutih odstupanja. Na dendrogramu, hijerarhijskom dijagramu u obliku stabla, grafičkim se putem prikazuje proces sukcesivnog formiranja klastera na osnovi sličnosti podataka pri čemu su na osi x visokoobrazovne institucije, a na osi y udaljenosti.

Grafikon 12: Dendrogram klaster analize visokoobrazovnih institucija ekonomskog usmjerenja temeljem rezultata relativne efikasnosti



Izvor: Izračun autorice

Identificirani klasteri objašnjavaju dvije različite grupacije temeljem rezultata relativne efikasnosti. Klaster 1 broji 20, a klaster 2 11 visokoobrazovnih institucija ekonomskog usmjerenja.

Tablica 34: DO raspoređeni u klasterne temeljem rezultata relativne efikasnosti tri različita područja vrednovanja

DO	GRUPE	DO	GRUPE	DO	GRUPE	DO	GRUPE
DO1	1	DO9	2	DO17	1	DO25	1
DO2	1	DO10	1	DO18	1	DO26	2
DO3	2	DO11	2	DO19	1	DO27	1
DO4	1	DO12	1	DO20	1	DO28	2
DO5	1	DO13	2	DO21	2	DO29	1
DO6	1	DO14	2	DO22	1	DO30	2
DO7	2	DO15	1	DO23	1	DO31	1
DO8	2	DO16	1	DO24	1		

Izvor: Izračun autorice

Nakon što su klasteri identificirani, temeljem D'Agostino Pearsonova testa testira se normalnost distribucije za svaku varijablu zasebno s ciljem izbora testova. Vrijednosti za MD normalno su distribuirane ($p = 0,1052$) dok se za ND i ZD ne nalazi normalna distribucija (za ND $p = 0,0002$, a za ZD $p = 0,0044$).

U sljedećem koraku provjeravamo karakteristike dviju grupa te utvrđujemo da grupa 1 predstavlja bolje rangirane, a grupa 2 lošije rangirane visokoobrazovne institucije temeljem rezultata relativne efikasnosti (Tablica 16). Kako većina varijabli nema normalnu distribuciju u analizi centralne tendencije koristi se neparametrijski Mann-Whitneyev test kako bi se utvrdilo ima li razlike u medijanima između grupa:

Kod varijable ND nalazimo medijalnu vrijednost od 0.93115 kod grupe 1 te medijalnu vrijednost od 0.2684 kod grupe 2 što prema Mann-Whitneyevom testu predstavlja statistički signifikantnu razliku ($p=0.0003$). Kod varijable ZD medijalna vrijednost je 0,93505 kod grupe 1 dok je kod grupe 2 ona 0,3557 što prema Mann-Whitneyevom testu predstavlja statistički signifikantnu razliku ($p=0.0033$). Kod varijable MD medijalna vrijednost je 0,48475 kod grupe 1 dok kod grupe 2 ona iznosi 0,3624 što prema Mann-Whitneyevom testu predstavlja statistički signifikantnu razliku ($p=0.0029$). Detaljni pokazatelji deskriptivne statistike za navedene varijable prikazani su u tablici 35.


Tablica 35: Karakteristike klastera i rezultati Mann-Whitney testa

GRUPE		ND	ZD	MD
1	N	20	20	20
	mean	0,76203	0,706705	0,56098
	sd	0,2898838	0,3481393	0,3398284
	p50	0,93115	0,93505	0,48475
	iqr	0,43225	0,5981	0,7247
2	N	11	11	11
	mean	0,2935727	0,2928909	0,2082455
	sd	0,1427167	0,1803555	0,1531127
	p50	0,2684	0,3557	0,1553
	iqr	0,2503	0,2494	0,2597
Total	N	31	31	31
	Mean	0,5958032	0,5598677	0,4358161
	Sd	0,3345496	0,3579277	0,3322454
	p50	0,5568	0,452	0,3624
	iqr	0,7276	0,7607	0,4777
Mann-Whitney				
Prob > z		0,0003	0,0033	0,0029

Izvor: Izračun autorice

Temeljem rezultata Mann-Whitneyevog testa indikativno je da je klaster analiza potvrdila kako je pripadnost institucija bolje rangiranoj grupi (grupa 1) određena višim rezultatima relativne efikasnosti za sva tri promatrana područja vrednovanja. Također, DO iz lošije rangirane grupe (grupa 2) ostvarili su niže rezultate relativne efikasnosti za sva tri promatrana područja vrednovanja. Navedene signifikantne razlike grafički su prikazane na sljedećem grafikonu.

Grafikon 13: Box plot za ND, ZD i MD po pojedinom klasteru



Izvor: Autorica

Nakon što su u drugoj fazi definirani klasteri te statistički potvrđene razlike među njima, pristupa se trećoj fazi u kojoj će se identificirati čimbenici od utjecaja za pozicioniranje unutar pojedinog klastera.

6.4. TREĆA FAZA MODELA – IDENTIFICIRANJE KLJUČNIH ČIMBENIKA PRIPADNOSTI POJEDINOM KLASTERU PRIMJENOM BINARNE LOGISTIČKE REGRESIJE

Logistička regresija (logit) je posebna vrsta regresijske analize koja, procjenjujući vjerojatnosti, mjeri odnos između zavisnih varijabli (kriteriji) izraženih kategorijama i jedne ili više nezavisne varijable (prediktori). Drugim riječima, ona je formulirana na način da predvidi i objasni kategorijske zavisne varijable (dihotomne, nemetričke) temeljem nezavisnih varijabli (mogu biti metričke i nemetričke). Logit predstavlja metodu kojim se predviđaju vjerojatnosti različitih mogućih ishoda kategorički postavljene zavisne varijable temeljem skupa nezavisnih varijabli. Logističkom regresijom predvidjet će se vjerojatnost prelaska iz jednog klastera u drugi sukladno promjeni nezavisne varijable. Vrijednost koja se dobije za zavisnu varijablu predstavlja omjer izgleda (eng. *odds ratio*). Omjer izgleda predstavlja omjer između vjerojatnost u slučaju postojanja određenog ishoda i vjerojatnosti kada to nije slučaj. Logistička regresija ne pretpostavlja linearnu zavisnost između zavisne i nezavisnih varijabli kao ni da zavisna varijabla ili standardne pogreške slijede normalnu distribuciju (Witten, Frank, 2005).

Model postavljen u trećoj fazi vrednovanja odnosi se na tradicionalan statični model logističke regresije gdje je zavisna varijabla dihotomna, odnosno njezine vrijednosti su prikazane s 0 i 1 pri čemu je vrijednost 1 dodijeljena DO grupiranim u bolje rangirani klaster 1, a vrijednost 0 DO grupiranim u lošije rangirani klaster 2. U ovoj fazi žele se utvrditi čimbenici koji utječu na rezultate relativne efikasnosti dobivene u prvoj fazi. U analizi je korišten softverski paket Stata/IC 13.0.

Kako se za logističku regresiju u ovom slučaju pretpostavlja barem 28 parametara po varijabli (Peduzzi i dr., 1996), a s obzirom da je veličina uzorka 31, ovaj skup podrazumijeva isključivo univarijantne modele. Zbog navedenog provodi se univarijantna binarna logistička regresija pri čemu je dihotomna zavisna varijabla formirana temeljem medijana. Analiziraju se varijable „Javn_Privat_Cat” koja daje informaciju o tipu vlasništva, „SRAD_Cat” – objavljeni stručni

radovi, "RASHUZNOS_Cat" – ukupni rashodi po znanstveno-nastavnom osoblju, "STUDZNOS_Cat" – broj studenata po znanstveno-nastavnom osoblju, "GOST_Cat" – gostujući predavači i znanstvenici, „ProfQ_Cat" – udio znanstveno- nastavnog osoblja u zvanju docenta, izvanrednog i redovnog profesora, "SPROJ_Cat" – stručni projekti, "Konkurencija_Cat" – broj institucija ekonomskog usmjerenja na određenom području (županija, regija, kanton), "BDPpc_Cat" – BDP p.c. na određenom području (županija, regija, kanton), "VELIČINA_Cat" – veličina institucije mjerena brojem upisanih studenata na preddiplomski i diplomski studij, "ZRAD_Cat" – objavljeni znanstveni radovi, "ZPROJ_Cat" – znanstveni projekti na instituciji, "VP_u_UP_Cat" – udio vlastitih prihoda u ukupnim prihodima.

Kako bi se definirale signifikantne varijable, prvo se koristi Cramerov V kao mjera povezanosti (eng. *measures of association*). Ova mjera koristi se kako bi se izmjerila snaga povezanosti između jedne nominalne varijable s drugom nominalnom ili ordinalnom varijablom. Kada Cramerov V ima vrijednost nižu od 0,2, radi se o izuzetno slaboj povezanosti. Poželjna veza je ona jača od 0,25. U slučajevima varijabli RASHUZNOS_Cat, STUDZNOS_Cat i GOST_Cat radi se o jakoj, vrlo povoljnoj vezi dok je ona za varijable Javn_Privat_Cat i SRAD_Cat ekstremno jaka.

Tablica 36: Snaga povezanosti između zavisne i nezavisnih varijabli Cramerov V

Varijable	CramerovV
Javn_Privat_Cat	0,4364
SRAD_Cat	0,4961
RASHUZNOS_Cat	0,3612
STUDZNOS_Cat	0,3612
GOST_Cat	0,3612
ProfQ_Cat	0,2263
SPROJ_Cat	0,2263
Konkurencija_Cat	0,1895
BDPpc_Cat	0,1398
VELIČINA_Cat	0,0914
ZRAD_Cat	0,0914
ZPROJ_Cat	0,0044
VP_u_UP_Cat	-0,0435

Izvor: Izrada autorice

Cramerovim V dobila se informacija o nezavisnim varijablama s kojima je zavisna varijabla umjereno jako, jako ili ekstremno jako povezana (Cramerov $V > 0,25$), a u nastavku će se univarijantnom binarnom logističkom regresijom povezanost iskazati kao snaga predikcije.

Tablica 37: Rezultati univarijantne binarne logističke regresije po svakoj varijabli

Varijable	Omjer izgleda	95% interval pouzdanosti	<i>p</i>
Javn_Privat_Cat	4	1,337285 – 11,96454	0,013
SRAD_Cat	7	1,590927 – 30,79966	0,01
RASHUZNOS_Cat	4,333332	1,234857 – 15,20643	0,022
STUDZNOS_Cat	4,333332	1,234857 – 15,20643	0,022
GOST_Cat	4,333332	1,234857 – 15,20643	0,022

Izvor: Izrada autorice

Omjer izgleda govori da je pripadnost bolje rangiranom klasteru 1 bila signifikantno viša za javne visokoobrazovne institucije ekonomskog usmjerenja, za institucije koje su objavile više stručnih radova, za institucije s višim udjelom ukupnih rashoda po znanstveno-nastavnom osoblju, za institucije s višim brojem studenata po znanstveno-nastavnom osoblju te za institucije s više gostujućih predavača i znanstvenika. Rezultati pokazuju kako bi prelaskom iz privatnih u javne visokoobrazovne institucije ekonomskog usmjerenja šansa za grupiranje u bolje rangirani klaster bila 4 puta viša. Također, one institucije koje pređu medijalnu vrijednost kod objave stručnih radova (SRAD_Cat povećaju za jednu mjernu jedinicu) imaju 7 puta veću šansu da se pozicioniraju u klaster 1. Povećaju li se ukupni rashodi po znanstveno-nastavnom osoblju za jednu mjernu jedinicu, institucije imaju 4,33 puta veću šansu da budu dio klastera 1. Institucije s većim brojem studenata po znanstveno-nastavnom osoblju pokazale su se relativno efikasnije te povećanjem varijable za jednu mjernu jedinicu te prelaskom prijelomne vrijednosti institucije imaju 4,33 puta veću šansu da budu klasificirane u bolje rangirani klaster 1. Također, institucije s većim brojem gostujućih predavača i znanstvenika pokazale su se relativno efikasnije te je vjerojatnost za pozicioniranje unutar klastera 1 veća za 4,33 puta kod institucija kojima se broj gostujućih predavača i znanstvenika poveća za jednu mjernu jedinicu.

Iako rezultati dvije varijable s najvišim omjerom izgleda mogu na prvi pogled djelovati nelogično jer se tradicionalno stručni rad povezuje s privatnim visokoobrazovnim institucijama, uvidom u podatke, utvrđeno je kako su javne visokoobrazovne institucije ekonomskog usmjerenja pokazale superiornost u objavi stručnih radova u odnosu na privatne (javne

visokoobrazovne institucije ekonomskog usmjerenja u promatranj 2012. godini imale su 2,1 puta više objavljenih stručnih radova po znanstveno nastavnom osoblju u odnosu na privatne visokoobrazovne institucije).

Gore prikazani rezultati dovode do zaključaka koji mogu poslužiti donositeljima obrazovne politike. Rezultati koji upućuju na bolju relativnu efikasnost javnih institucija u odnosu na privatne logičan je i očekivan iz nekoliko razloga. Kao što je navedeno u samoj problematici istraživanja, obrazovanje je jedan od strateških ciljeva svake nacionalne ekonomije i kao takvo je od javnog interesa, a same funkcije institucija obuhvaćaju i ispunjavanje određenih javnih ciljeva (obrazovanje stanovništva i povećanje opće produktivnosti kroz kvalitetne kadrove, produkcija znanstvenih i stručnih radova koji bi trebali pružiti smjernice za ekonomski i društveni razvoj, povezivanje s inozemnim institucijama s ciljem usvajanja novih znanja i vještina). S obzirom da su javne visokoobrazovne institucije tradicionalno više usmjerene postizanju ciljeva u svim navedenim područjima dok su privatne više okrenute svojoj financijskoj održivosti za očekivati je da će javne visokoobrazovne institucije biti više usmjerene na ostvarivanje promatranih ciljeva. Kako je znanstveno-nastavno osoblje najviše odgovorno za provođenje gore navedenih ciljeva, njihova motiviranost i uvjeti rada uvelike će određivati razinu ostvarene relativne efikasnosti matične institucije. Zbog toga su viši ukupni rashodi po znanstveno-nastavnom osoblju bitna pretpostavka ostvarivanja boljih rezultata. Činjenica da je za rezultat relativne efikasnosti bitan viši broj gostujućih predavača i znanstvenika također govori o važnosti ulaganja u ljudske potencijale koja se odražava kroz veću umreženost i prepoznatljivost institucije i njezinog znanstveno-nastavnog osoblja. Za pretpostaviti je da će bolja prepoznatljivost institucije dovesti do većeg broja gostujućih predavača i znanstvenika. Prepoznatljivost institucije nije ograničena samo u vidu međunarodne suradnje već se može promatrati i u okviru gospodarske djelatnosti. Stoga, veza između rezultata relativne efikasnosti i broja stručnih radova daje informaciju o stručnosti i kompetencijama djelatnika visokoobrazovne institucije unutar gospodarske zajednice. Također, interes studenata za upis na određenu visokoobrazovnu instituciju usko je povezan s njezinom prepoznatljivošću i kvalitetom provođenja djelatnosti koja se između ostaloga manifestira i kroz rezultate relativne efikasnosti.

6.5. ALTERNATIVNI MODEL VREDNOVANJA RELATIVNE EFIKASNOSTI VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA

Pri testiranju originalnog modela utvrđen je vrlo visok utjecaj stručnog rada za pripadnost bolje rangiranom klasteru 1. Alternativni model, s obzirom na prirodu visokoobrazovnih institucija ekonomskog usmjerenja koje značajno veću važnost pridaju znanstvenom u odnosu na stručni rad, dat će prikaz rezultata ukoliko se kod ZD kao output uzimaju isključivo znanstveni radovi (ZD_1). Alternativni model će, kao i originalan biti postavljen kroz jednake faze.

1. faza: Testiranje alternativnog modela vrednovanja relativne efikasnosti javnih ekonomskih fakulteta primjenom analize omeđivanja podataka

S obzirom da su izmjene vršene jedino u području znanstvene djelatnosti, statistika inputa i outputa i koeficijenti korelacije za ZD_1 prikazani su u nastavku.

Tablica 38: Deskriptivna statistika inputa i outputa za model znanstveno-stručna djelatnost

	ZNOS	ZPROJ	ZRAD
Max	238	32	472
Min	10	0	0
Average	52,5806	4,6129	68,1935
SD	44,7306	7,43435	100,86

Izvor: Izračun autorice

Tablica 39: Koeficijenti korelacije inputa i outputa za model znanstveno-stručna djelatnost

	ZNOS	ZPROJ	ZRAD
ZNOS	1	0,80232	0,85921
ZPROJ	0,80232	1	0,921
ZRAD	0,85921	0,921	1

Izvor: Izračun autorice

Nakon uvida u deskriptivnu statistiku i koeficijente korelacije pristupa se odabiru modela. Uspoređuju se rezultati relativne efikasnosti 31 visokoobrazovne institucije ekonomskog usmjerenja prema CCR i BCC outputu usmjerenom modelu. S obzirom da postoji značajno

odstupanje u broju relativno efikasnih ($\theta^* = 1$) DO koristi se BCC outputu usmjeren model koji podrazumijeva varijabilne prinose na opseg poslovanja (kod originalnog modela korišten je CCR model koji podrazumijeva konstantne prinose na opseg poslovanja).

Tablica 40: Rezultati relativne efikasnosti primjenom CCR i BCC modela s output orijentacijom za model ZD_1

	Znanstvena djelatnost_1	
	CCR	BCC
Broj efikasnih DO	4	7
Broj neefikasnih DO	27	24
Prosječan rezultat	0,4956	0,5351
Maksimalan rezultat	1	1
Minimalan rezultat	0,0001	0,0001

Izvor: Izračun autorice

Nakon što je izabran BCC outputu usmjeren model, u sljedećoj tablici prikazani su rezultati relativne efikasnosti ZD_1 po svakom DO, rang svakog DO, učestalost, odnosno frekvencije pojavljivanja relativno efikasnih DO u referentnom skupu te su predstavljeni članovi referentnog skupova relativno neefikasnih visokoobrazovnih institucija.

Tablica 41: Učestalost pojavljivanja relativno efikasnih visokoobrazovnih institucija u referentnom skupu i članovi referentnog skupa za model ZD_1

DO	ZD_1 - BCC	Rang	Frekv.	referentni skup (λ)
DO1	0,4535	15		DO27, DO29
DO2	0,4573	14		DO4, DO27
DO3	0,5985	12		DO4, DO27
DO4	1	1	6	DO4
DO5	0,3392	23		DO4, DO24, DO27
DO6	1	1	12	DO6
DO7	0,3616	22		DO24, DO27, DO29
DO8	0,2281	24		DO17, DO24, DO29
DO9	0,1944	25		DO6
DO10	0,4722	13		DO6
DO11	0,0001	31		DO6
DO12	0,4058	19		DO6, DO17
DO13	0,4516	16		DO6, DO17
DO14	0,0002	30		DO6, DO17
DO15	0,0921	29		DO6, DO17
DO16	1	1	1	DO16
DO17	1	1	10	DO17

Tablica 41 - nastavak

DO18	0,8701	10		DO6, DO17
DO19	0,0942	28		DO17, DO24, DO29
DO20	0,758	11		DO6, DO17
DO21	0,1667	26		DO6
DO22	0,1389	27		DO6
DO23	0,9909	8		DO27, DO29
DO24	1	1	10	DO24
DO25	0,8808	9		DO4, DO24, DO27
DO26	0,3669	21		DO24, DO27, DO29
DO27	1	1	10	DO27
DO28	0,3813	20		DO17, DO24, DO29
DO29	1	1	9	DO29
DO30	0,445	17		DO24, DO27, DO29
DO31	0,4402	18		DO4, DO24

Izvor: Izračun autorice

Podaci o prosječnim poboljšanjima za relativno neefikasne visokoobrazovne institucije prikazani su sljedećom tablicom, a detaljna tablica s prosječnim poboljšanjima po svakom DO nalazi se u prilogu 2.

Tablica 42: Podaci o prosječnim poboljšanjima (projekcijama) za relativno neefikasne visokoobrazovne institucije

ZRAD		
	Data	Projection
Average	68,1935	103,5086


Izvor: Izračun autorice

Nakon prve faze vrednovanja relativne efikasnosti visokoobrazovnih institucija ekonomskog usmjerenja analizim omeđivanja podataka (alternativni model), pristupa se drugoj fazi vrednovanja gdje se klaster analizim utvrđuje pripadnost pojedinom klasteru sukladno ostvarenim rezultatima relativne efikasnosti iz prve faze vrednovanja.

2. faza – Grupiranje DO primjenom klaster analize

Na dendrogramu, je grafičkim se putem prikazan proces sukcesivnog formiranja klastera na osnovi sličnosti rezultata relativne efikasnosti (varijabli ND, ZD_1 i MD). Na osi x prikazane su visokoobrazovne institucije, a na osi y udaljenosti.

Grafikon 14: Dendrogram klaster analize visokoobrazovnih institucija ekonomskog usmjerenja temeljem rezultata relativne efikasnosti (alternativni model)



Izvor: Autorica

Identificiranirana su dva klastera temeljem rezultata relativne efikasnosti. Klaster 1 broji 19, a klaster 2 12 visokoobrazovnih institucija ekonomskog usmjerenja (Razlika u odnosu na originalan model je u tome što DO10 koji je prema originalnom modelu bio svrstan u klaster 1, u alternativnom modelu je svrstan u klaster 2). Raspored DO po klasterima dan je u tablici 42.

Tablica 43: DO raspoređeni u klasterne temeljem rezultata relativne efikasnosti tri različita područja vrednovanja (alternativni model)

	GRUPE_1		GRUPE_1		GRUPE_1		GRUPE_1
DO1	1	DO9	2	DO17	1	DO25	1
DO2	1	DO10	2	DO18	1	DO26	2
DO3	2	DO11	2	DO19	1	DO27	1
DO4	1	DO12	1	DO20	1	DO28	2
DO5	1	DO13	2	DO21	2	DO29	1
DO6	1	DO14	2	DO22	1	DO30	2
DO7	2	DO15	1	DO23	1	DO31	1
DO8	2	DO16	1	DO24	1		

Izvor: Izračun autorice

Nakon što su klasteri identificirani, temeljem D'Agostino Pearsonova testa testira se normalnost distribucije za svaku varijablu zasebno kako bi se utvrdilo je li uputno koristiti parametrijske ili neparametrijske testove. S obzirom da se varijable ND i MD nisu mijenjale, kao i kod originalnog modela se utvrđuje da su vrijednosti za MD normalno su distribuirane ($p = 0,1052$) dok se za ND ne nalazi normalna distribucija ($p = 0,0002$). Testiranjem varijable ZD_1 utvrđuje se da niti kod nje podaci nisu normalno distribuirani ($p=0.0145$).

Nakon raspoređivanja DO u pripadajuće klastere (grupe), u sljedećem koraku provjeravaju se karakteristike dviju identificiranih grupa te se utvrđuje da grupa 1 predstavlja bolje rangirane, a grupa 2 lošije rangirane visokoobrazovne institucije temeljem rezultata relativne efikasnosti (tablica 43). Kako većina varijabli nema normalnu distribuciju u analizi centralne tendencije koristi se neparametrijski Mann-Whitneyev test kako bi se utvrdilo ima li razlike u medijanima između grupa.

Tablica 44: Karakteristike klastera i rezultati Mann-Whitney testa (alternativni model)


GRUPE_1		ND	ZD_1	MD
1	N	19	19	19
	mean	0,78462	0,68005	0,56987
	sd	0,27915	0,35177	0,34674
	p50	0,9469	0,8701	0,4868
	iqr	0,4213	0,5942	0,7955
2	N	12	12	12
	mean	0,29684	0,30555	0,22356
	sd	0,13655	0,18858	0,15533
	p50	0,3006	0,36425	0,21215
	iqr	0,19245	0,26775	0,2599
Total	N	31	31	31
	mean	0,5958	0,53508	0,43582
	sd	0,33455	0,34881	0,33225
	p50	0,5568	0,4516	0,3624
	iqr	0,7276	0,7628	0,4777
Mann-Whitney Prob > z		0,0001	0,008	0,005

Izvor: Izračun autorice

Kod varijable ND nalazimo medijalnu vrijednost od 0.9469 kod grupe 1 te medijalnu vrijednost od 0.3006 kod grupe 2 što prema Mann-Whitneyevom testu predstavlja statistički signifikantnu razliku ($p=0.0001$). Kod varijable ZD_1 medijalna vrijednost je 0,8701 kod grupe 1 dok je kod grupe 2 ona 0,36425 što prema Mann-Whitneyevom testu predstavlja statistički signifikantnu razliku ($p=0.008$). Kod varijable MD medijalna vrijednost je 0,4868 kod grupe 1 dok kod grupe 2 ona iznosi 0,21215 što prema Mann-Whitneyevom testu predstavlja statistički signifikantnu razliku ($p=0.005$). Detaljni pokazatelji deskriptivne statistike za navedene varijable prikazani su u tablici 43.

Sukladno rezultatima Mann-Whitneyevog testa, klaster analizom je potvrđeno kako viši rezultati relativne efikasnosti za sva tri promatrana područja određuju pripadnost institucija bolje rangiranoj grupi (grupa 1) dok su DO iz lošije rangirane grupe (grupa 2) ostvarili niže rezultate relativne efikasnosti za sva tri promatrana područja vrednovanja. Navedene signifikantne razlike grafički su prikazane sljedećim grafikonom.

Grafikon 15: Box plot za ND, ZD_1 i MD po pojedinom klasteru (alternativni model)



Izvor: Autorica

Nakon druge faze u kojoj su definirani klasteri te statistički potvrđene razlike među njima, pristupa se trećoj fazi u kojoj će se identificirati čimbenici koji imaju utjecaj na pripadnost pojedinom klasteru.

3. faza – Identificiranje ključnih čimbenika pripadnosti pojedinom klasteru primjenom binarne logističke regresije (alternativni model)

U prvom koraku treće faze vrednovanja, s ciljem definiranja signifikantnih varijabli, koristi se Cramerov V kao kako bi se izmjerila snaga povezanosti između zavisne i nezavisne varijable. U analizu su uključene sve varijable iz originalnog modela izuzev varijable SRAD_Cat koja je izostavljena iz modela. Poželjna veza je ona jača od 0,25. U slučajevima varijabli RASHUZNOS_Cat, STUDZNOS_Cat i GOST_Cat, ProfQ_Cat i SPROJ_Cat radi se o umjerenom povezanosti dok je ona za varijablu Javn_Privat_Cat ekstremno jaka.

Tablica 45: Snaga povezanosti između zavisne i nezavisnih varijabli Cramerov V (alternativni model)

Varijable	Cramerov V - Grupe 1
Javn Privat Cat	0,5179
RASHUZNOS_Cat	0,2907
STUDZNOS_Cat	0,2907
GOST_Cat	0,2907
ProfQ_Cat	0,2907
SPROJ_Cat	0,2907

Konkurencija_Cat	0,1299
BDPpc_Cat	0,0773
VELIČINA_Cat	0,0256
ZRAD_Cat	0,1582
ZPROJ_Cat	0,0773
VP_u_UP_Cat	-0,1069

Izvor: Izračun autorice

Nakon što se Cramerovim V dobila se informacija o nezavisnim varijablama s kojima je zavisna varijabla umjereno jako, jako ili ekstremno jako povezana (Cramerov $V > 0,25$), pristupa se drugom koraku treće faze vrednovanja gdje se univarijantnom binarnom logističkom regresijom dobivena povezanost može iskazati kao snaga predikcije.

Omjerom izgleda utvrđuje se da je pripadnost bolje rangiranom klasteru 1 bila signifikantno viša za javne visokoobrazovne institucije ekonomskog usmjerenja. Iako je Cramerovim V utvrđena umjerena povezanost varijabli RASHUZNOS_Cat, STUDZNOS_Cat i GOST_Cat,

ProfQ_Cat i SPROJ_Cat s zavisnom varijablom (klaster1 i klaster2), unatoč p vrijednosti, s obzirom na vrijednosti intervala pouzdanosti (obje, i niža i viša vrijednost intervala pouzdanosti moraju biti ili ispod 1 ili iznad 1 kako bi rezultati bili signifikantni), za spomenute varijable, iako postoji povezanost s zavisnom varijablom, nije moguće statističkom značajnosti utvrditi vjerojatnosti prelaska u povoljniji klaster. Sukladno rezultatima može se zaključiti kako bi prelaskom iz privatnih u javne visokoobrazovne institucije ekonomskog usmjerenja šansa za pripadnost bolje rangiranom klasteru bila 4 puta viša.

Tablica 46: Rezultati univarijantne binarne logističke regresije po svakoj varijabli (alternativni model)

Varijable	Omjer izgleda	95% interval pouzdanosti	p
Javn Privat_Cat	4	1,337285 – 11,96454	0,013
RASHUZNOS_Cat	3	0.9675642 - 9.301708	0,057
STUDZDOS_Cat	3	0.9675642 - 9.301708	0,057
GOST_Cat	3	0.9675642 - 9.301708	0,057
ProfQ_Cat	3	0.9675642 - 9.301708	0,057
SPROJ_Cat	3	0.9675642 - 9.301708	0,057

Izvor: Izračun autorice

6.6. UČINCI PRIMJENE MODELA VREDNOVANJA RELATIVNE EFIKASNOSTI VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA

Pretpostavlja se da bi kontinuirana primjena modela vrednovanja relativne efikasnosti javnih visokoobrazovnih institucija ekonomskog usmjerenja uvelike utjecala na porast efikasnosti i posljedično kvalitete institucija koja bi dovela do brojnih pozitivnih implikacija kako za same institucije, tako i za visoko obrazovanje i društvo općenito. Uvid institucija u svoju poziciju u odnosu na sebi slične služio bi im kao orijentir, a prijedlog mjera za poboljšanje omogućavao bi promjene u smjeru efikasnijeg poslovanja.

Učinci predloženog modela ne očituju se isključivo na razini pojedine institucije i njezine usporedbe s drugim institucijama već mogu služiti i kao smjernica za oblikovanje obrazovne politike te na moderiranje smjernica od strane nacionalnih tijela. Rezultati i originalnog i

alternativnog modela ističu tip vlasništva kao ključnu varijablu za ostvarivanje relativno efikasnijeg poslovanja. S obzirom da su javne visokoobrazovne institucije ekonomskog usmjerenja, za razliku od privatnih, tradicionalno više usmjerene ostvarivanju ciljeva od javnog interesa, pokazale su se kako raspoložive resurse koriste relativno efikasnije u tri promatrana segmenta djelovanja. Privatne visokoobrazovne institucije se, za razliku od javnih, primarno vode financijskom održivosti što se jasno reflektira na ostvarene rezultate relativne efikasnosti. Sukladno tome, s aspekta modela vlasništva, rezultati nalažu preferiranje javnih visokoobrazovnih institucija ekonomskog usmjerenja nad privatnima.

Izuzev tipa vlasništva, varijable koje su se u oba modela pokazale povezane s ostvarenom razinom relativne efikasnosti su ukupni rashodi po znanstveno-nastavnom osoblju, studenti po znanstveno-nastavnom osoblju te gostujući predavači i znanstvenici. Navedeni rezultati daju vrijedne informacije koje su djelomično u suprotnosti s pojedinim potezima politika visokog obrazovanja koje idu u smjeru smanjivanja naknada zaposlenima i institucijama općenito kao i smanjivanja broja studenata. U budućim istraživanjima trebalo bi se ići u smjeru izračuna prijelomne vrijednosti (eng. *cut off*), odnosno optimalne vrijednosti ukupnih rashoda po znanstveno-nastavnom osoblju, kao i broja studenata po znanstveno-nastavnom osoblju za ostvarivanje više razine relativne efikasnosti. Broj gostujućih predavača i znanstvenika usko je vezan uz rashode po znanstveno-nastavnom osoblju. Viša ulaganja u znanstveno-nastavni kadar i uvjete rada dovode do više motiviranosti, umreženosti s drugim institucijama te prepoznatljivosti institucije čime se direktno utječe na privlačenje gostujućih predavača i znanstvenika što posljedično utječe na efikasnost poslovanja.

Varijable koje su se pokazale povezane s ostvarenom razinom relativne efikasnosti su i broj stručnih radova u originalnom modelu te udio znanstveno-nastavnog osoblja u zvanju docenta, izvanrednog i redovnog profesora u alternativnom modelu. Iako se na prvi pogled ovi rezultati mogu činiti nelogičnima s obzirom da se tradicionalno stručni radovi i projekti vežu uz institucije u privatnom vlasništvu, uvidom u podatke, javne visokoobrazovne institucije ekonomskog usmjerenja pokazale su superiornost u oba segmenta. Sukladno rezultatima, nacionalna tijela koja se bave evaluacijom visokoobrazovnih institucija i donosioci obrazovne politike trebali bi se usuglasiti da li bi bilo opravdano stručnoj djelatnosti koju provode visokoobrazovne institucije ekonomskog usmjerenja pružiti veći značaj pri postupcima evaluacije, kod odluka o financiranju i sl. U alternativnom modelu se i varijabla udio znanstveno-nastavnog osoblja u zvanju docenta, izvanrednog i redovnog profesora pokazala

povezana s klasterom formiranim temeljem rezultata relativne efikasnosti. Ovo je zanimljiva i korisna informacija s obzirom na novije politike koje se provode u Hrvatskoj s ciljem usporavanja napredovanja znanstveno-nastavnog osoblja. S obzirom na rezultate koji dovode u vezu pripadnost bolje rangiranom klasteru i udio znanstveno-nastavnog osoblja u zvanju docenta, izvanrednog i redovnog profesora, trebalo bi se preispitati jesu li postojeće politike napredovanja opravdane. Mogućnost bržeg napredovanja znanstveno-nastavnog osoblja sukladno ostvarenim uvjetima mogla bi pozitivno utjecati na njihovu motiviranost i posljedično na ostvarivanje efinasnijeg poslovanja.

Osnova osiguravanja i održavanja kvalitete visokoobrazovne institucije je u redovitom vrednovanju poslovnih procesa. Ukoliko se vrednovanje ne vrši, izuzetno je teško provoditi ispravne korake. Bez tog segmenta teško se može utvrditi u kojem smjeru se mjere trebaju provoditi. Kako bi se vrednovanje vršilo kontinuirano, potrebno je koristiti jednostavne modele koji će pružiti brzu i sveobuhvatnu informaciju o kvaliteti promatranih procesa.

Posljednjih godina u Hrvatskoj su se počeli stvarati pomaci po pitanju osiguravanja kvalitete u prostoru visokog obrazovanja. Veliku ulogu imaju vanjska, unutarnja evaluacija te odbori za osiguranje kvalitete. Unatoč tome, potrebno je konstantno vršiti napore i tražiti nova, jednostavnija rješenja koja bi doprinijela ovom općem cilju. Predloženi empirijski model dopuna je postojećim metodama evaluacije koji, iako primijenjen na visokoobrazovne institucije ekonomskog usmjerenja, uz manje prilagodbe mogao bi se prilagoditi potrebama i ostalih visokoobrazovnih institucija. Kako bi postignuti rezultati imali svoju svrhu, bitno je da budu čim transparentniji. To podrazumijeva stvaranje mreže homogenih visokoobrazovnih institucija koje bi, međusobnom usporedbom, sustavno djelovale na poboljšanje ili održavanje svoje pozicije

7. KVALITATIVNI MODEL VREDNOVANJA EFEKTIVNOSTI VISOKOOBRAZOVNIH INSTITUCIJA EKONOMSKOG USMJERENJA

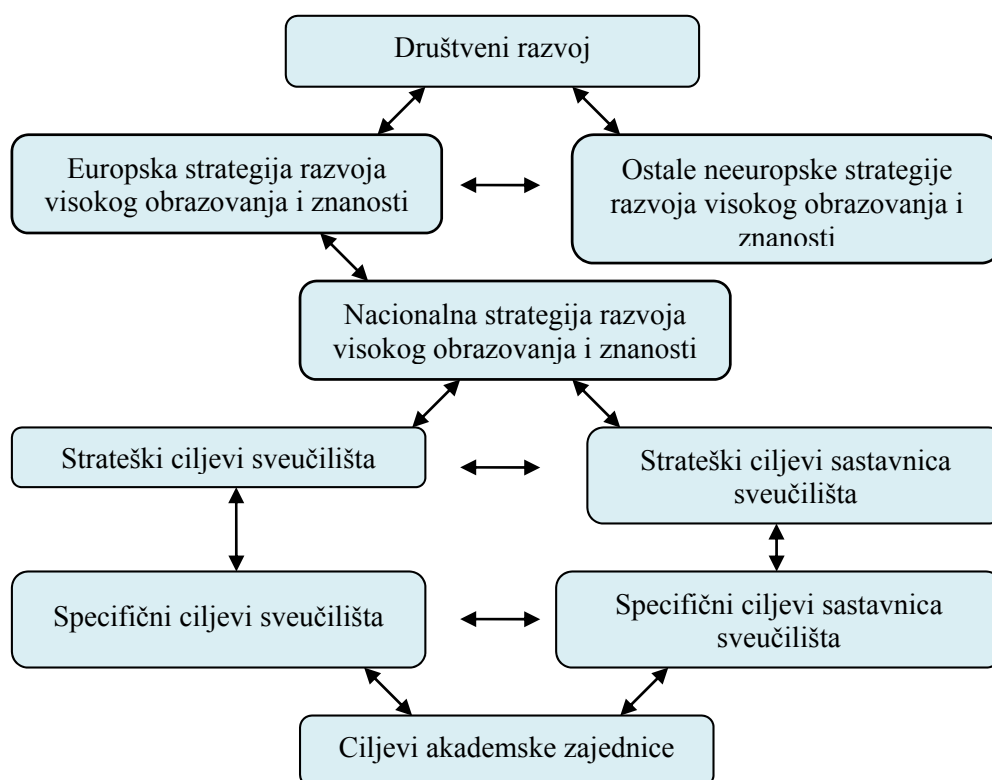
Iako empirijski, kvantitativni model vrednovanja relativne efikasnosti pozicionira visokoobrazovne institucije ekonomskog usmjerenja temeljem ostvarenih rezultata, u svrhu promicanja kvalitete i kontinuiranog napretka uputno je koristiti i kvalitativne modele koji bi dali detaljniji uvid u poslovanje institucija. U okviru ovog dijela rada je postavljen teorijski okvir za vrednovanje efektivnosti visokoobrazovnih institucija.

7.1. HIJERARHIJA CILJEVA KAO OKVIR KVALITATIVNOG MODELA VREDNOVANJA EFEKTIVNOSTI

Unutarnje vrednovanje ishoda na razini pojedine visokoobrazovne institucije je poželjno, ispravno, ali ne i dovoljno. S obzirom da su sve visokoobrazovne institucije u RH i regiji dio šireg sustava, u prvom redu nacionalnog, pa potom i europskog, nužno je usuglasiti njihova međusobna djelovanja na način da niže razine budu u funkciji viših razina kako bi se postignula homogenost europskog visokoobrazovnog sustava.

Kako bi ostvarile zadanu razinu kvalitete, visokoobrazovne institucije prije svega moraju ispravno postaviti svoje ciljeve. Ispravno postavljeni ciljevi su oni koji služe kao smjernica održivog poslovanja te moraju biti povezani, ne samo s nacionalnom visokoobrazovnom strategijom, nego i sa strategijom definiranom na razini Europe. Pri njihovom definiranju nužno je imati u vidu razvoj cjelokupnog društva kao krajnji output. Prijedlog definiranja ciljeva visokog obrazovanja prikazan je na sljedećoj shemi.

Shema 18: Definiranje ciljeva razvoja visokog obrazovanja



Izvor: Izrada autorice

Ciljevi svih razina, ukoliko su definirani na ispravan način, biti će u povezani na svim razinama te će kao takvi biti u službi ostvarivanja društvenog i gospodarskog napretka.

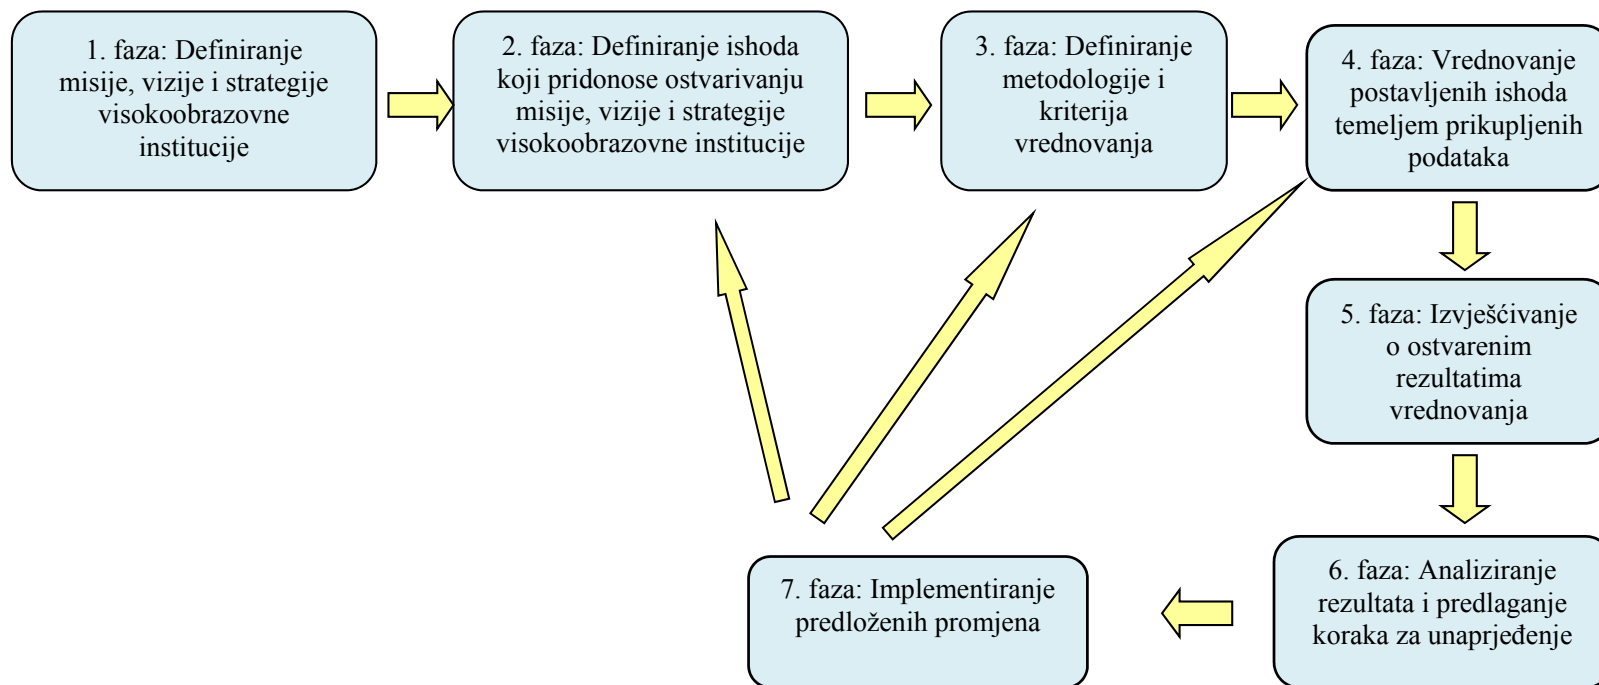
Problematika kvalitativnog vrednovanja postavljenih ciljeva leži, između ostaloga, u tome što ne postoje razvijeni mehanizmi vrednovanja kvalitativnih veličina. One se promatraju isključivo kroz kvantitativne mjere koje često ne odražavaju pravu prirodu veličine koja se vrednuje. Također, važno je ciljeve svih razina međusobno uskladiti i koordinirano promatrati njihovo izvođenje.

Jurlina Alibegović i Sljepčević (2012) naglašavaju problematiku mjerenja ostvarenih ciljeva u Hrvatskoj koja postoji prvenstveno iz razloga što indikatori uspješnosti (eng. performance indicators) nisu definirani na ispravan način kako bi mjerili ostvarenje rezultata u odnosu na postavljene prioritete i ciljeve. Također ističu važnost oblikovanja budućih strateških dokumenata na način da budu kompatibilni s prioritetima, ciljevima i mjerama uspješnosti promatranog subjekta.

7.2. FAZE MODELA VREDNOVANJA EFEKTIVNOSTI

Efektivnost institucije predstavlja proces kojim institucija definira koliko uspješno je ostvarila zadanu misiju. Pritom je ispravno definiranje misije kao i samih ishoda koje je potrebno ostvariti ključno za ostvarivanje više razine efektivnosti. Sami ishodi moraju biti mjerljivi. Kontinuirano vrednovanje efektivnosti institucije daje uvid u to ostvaruje li institucija napredak ili ne (The University of Texas at Austin, 2013). Ukoliko se koncept institucionalne efektivnosti primijeni na primjeru visokoobrazovnih institucija, važno je prije svega utvrditi što je bitno, definirati ishode, pratiti ih i koristiti rezultate za ostvarivanje efektivnijeg poslovanja. S obzirom da je nužan preduvjet ostvarivanja efektivnosti ostvarivanje efikasnosti iz razdoblja u razdoblje, pri definiranju ciljeva i provođenju radnji za njihovo ostvarenje treba u obzir uzeti rezultate relativne efikasnosti dobivene u prvoj fazi kao i prijedloge za njezino poboljšanje. Navedeno je prikazano na sljedećoj shemi.

Shema 19: Proces unutarnjeg vrednovanja ishoda u funkciji ostvarivanja efektivnosti visokoobrazovnih institucija



Izvor: Izrada autorice

Prijedlog procesa definiranja i vrednovanja ishoda sa svrhom ostvarivanja efektivnijeg poslovanja visokoobrazovnih institucija sastoji se od 7 faza. U **1. fazi** definira se sama misija institucije koja predstavlja osnovnu funkciju bez koje njezino poslovanje nema smisao, viziju koja predstavlja njezinu idealnu budućnost te strategiju koja pretpostavlja određene radnje sa svrhom ostvarivanja željenih ciljeva. Iz misije, vizije i strategije institucije interno tijelo za unaprjeđenje kvalitete uz podršku menadžmenta institucije definira u **2. fazi** ciljeve i ishode koje će institucija nakon određenog razdoblja biti u mogućnosti ostvariti i mjeriti. **3. faza** je izuzetno bitna jer se u njoj od strane internog tijela za unaprjeđenje kvalitete definira metodologija vrednovanja postavljenih ishoda kao i kriteriji vrednovanja kojih se vrednovatelji trebaju pridržavati. Za treću fazu, kao jedan od segmenata vrednovanja predlaže se metodologija vrednovanja relativne efikasnosti primijenjena u empirijskom dijelu doktorske disertacije. **4. faza** predstavlja sam proces vrednovanja čiji se rezultati izvješćuju u **5. fazi**. Nakon izvješćivanja rezultata, interno tijelo za unaprjeđenje kvalitete u suradnji s menadžmentom institucije analizira rezultate te zajednički predlažu korake za unaprjeđenje što je predmet **6. faze**. U posljednjoj, **7. fazi** menadžment vrši implementaciju predloženih promjena. Te prilagodbe se mogu očitovati u nekoliko smjerova. Ukoliko ishodi nisu bili ispravno, realno ili mjerljivo postavljeni, oni će se trebati mijenjati. Same metode i kriteriji vrednovanja podložni su promjenama zbog novih spoznaja o istima. Ukoliko se kroz određeni period utvrdi da korištenje nekih drugih metoda daje ispravnije rezultate, potrebno je njih koristiti. Također, ako kriteriji vrednovanja nisu dobro postavljeni potrebno ih je ispraviti. Ukoliko su ishodi ispravno postavljeni, metode vrednovanja zadovoljavajuće, a kriteriji vrednovanja realni, nakon prilagođavanja institucije predloženim promjenama može se odmah pristupiti prikupljanju novih podataka i informacija temeljem kojih se vrednuju postavljeni ishodi. Jednim od tri predložena pravca otvara se novi ciklus vrednovanja.

8. ZAKLJUČAK

Pitanje kvalitete visokoobrazovnih institucija postalo je jedno od centralnih područja interesa, kako zemalja Europe i svijeta, tako i Republike Hrvatske. S obzirom da visoko obrazovanje predstavlja jedan od strateških ciljeva svake nacionalne ekonomije, ono je većinom financirano iz državnog proračuna, odnosno novcem poreznih obveznika. Zbog toga je nužno da porezni obveznici imaju uvid u što se ulaže njihov novac te jesu li ta sredstva efikasno iskorištena. Navedena problematika dobila je još veći značaj uslijed djelovanja gospodarske krize. Ekonomije se suočavaju sa snažnim pritiskom da novac koji ulože rezultira što boljim rezultatima. Zato je nužno mjeriti efikasnost visokoobrazovnog sustava kako bi se područja efikasnog poslovanja razdvojila od onih koja posluju neefikasno te kako bi se primijenile odgovarajuće mjere za poboljšanje njihovih rezultata. Vrednovanje efikasnosti i efektivnosti u području visokog obrazovanja dio je područja interesa velikog broja znanstvenika. Unatoč naporima, postojeće stanje vrednovanja odrednica kvalitete visokoobrazovnih institucija u Hrvatskoj i većini zemalja regije još uvijek nije u potpunosti zadovoljavajuće. Posljednjih godina jača znanstveni interes za ovom temom, prije svega potaknut velikim promjenama u visokoobrazovnom sustavu te institucionalnom analizom razine kvalitete visokoobrazovnih institucija kroz postupke vanjske i unutarnje evaluacije.

Uvođenjem Bolonjskog procesa došlo je do promjena visokoobrazovnog sustava na području zemalja EU sa svrhom stvaranja tzv. Europskog prostora visokog obrazovanja. Njega, u prvom redu, karakterizira usporedivost diploma i kvalifikacija, ostvarivanje mobilnosti studenata i akademskog osoblja te ostvarivanje unificirane razine kvalitete visokog obrazovanja. Problem se očituje, prije svega, u socio-demografskoj heterogenosti zemalja članica EU, ali se sustavnim pristupom nastoje umanjiti prepreke održivosti ovog novog reformiranog sustava visokog obrazovanja.

Visoka učilišta se osnivaju kao ustanove, a temeljna djelatnost im je pružanje usluge visokog obrazovanja. Sukladno tome, ona ustrojavaju i izvode studije, a ovlaštena su i za obavljanje poslova znanstvenog, visokostručnog ili umjetničkog rada. U Republici Hrvatskoj se u visoka učilišta ubrajaju sveučilišta, veleučilišta i visoke škole. Pritom se sveučilišta sastoje od fakulteta, akademija i odjela.

Osnovna razlika između privatnih poduzeća i visokoobrazovnih institucija je u tome što su privatna poduzeća primarno orijentirana stvaranju profita i profit kao takav je osnovni pokazatelj njihova uspjeha. Iako sve više privatnih poduzeća uvodi sustav društvene odgovornosti, ipak im je profit osnovni cilj. Ovakvo usmjerenje direktno utječe na formiranje sustava financijskog i menadžerskog računovodstva koje koriste. Za razliku od privatnih poduzeća, visokoobrazovne institucije kao subjekti javnog sektora svoje ciljeve formiraju na način da oni pridonose ostvarivanju zadovoljstva njegovih korisnika. Pritom su financijska sredstva ključna za obavljanje visokoobrazovne djelatnosti na kvalitetan način. Visokoobrazovne institucije, kako u Hrvatskoj, tako i u zemljama regije primarno se financiraju javnim sredstvima te nisu tržišno orijentirane. Iako su javna sredstva dominantna u strukturi njihovih prihoda, sve veći značaj pridaje se privatnim izvorima financiranja. Uslijed djelovanja gospodarske krize počela se pridavati dodatna pažnja financiranju visokoobrazovnih institucija zbog čega je ono postalo jedna je od važnijih tema kako u Hrvatskoj, tako i u svijetu.

S obzirom da priroda poslovanja visokoobrazovnih institucija nije profitno orijentirana, nije prikladno koristiti tradicionalno financijsko i menadžersko računovodstvo bez prilagođavanja njihovim specifičnostima. Proračunski korisnici koriste računovodstvene sustave koji uglavnom zadovoljavaju potrebe financijskog računovodstva koje podrazumijeva vanjsko izvješćivanje. Iako se ističe važnost internog izvješćivanja po pitanju praćenja i proučavanja troškova, ipak su ti sustavi slabije razvijeni.

Za razliku od eksternog financijskog izvješćivanja, kod internog nisu zakonski propisana izvješća koja bi trebali primjenjivati svi proračunski korisnici. Interni obračun ima svrhu zadovoljavanja internih korisnika koji se dobivenim informacijama koriste u upravljanju, odlučivanju i planiranju. Pritom se prilikom internog obračuna u obzir uzimaju specifičnosti svakog poduzeća ili institucije. Interno financijsko izvješćivanje ulazi u domenu troškovnog i upravljačkog računovodstva, a podaci i informacije dobivene ovim putem trebaju služiti menadžmentu u planiranju i donošenju poslovnih odluka. Time se doprinosi rastu kvalitete računovodstvenih informacija jer troškovno i upravljačko računovodstvo imaju direktan utjecaj na zadovoljenje javnih potreba kao i na razinu ostvarene efikasnosti i efektivnosti pružanja usluga. Iako interno i eksterno izvješćivanje nisu metodološki usklađeni, u novije vrijeme postoje inicijative kojima bi se ove dvije metodologije izvještavanja standardizirale. Time bi se osiguralo transparentnije poslovanje i jednostavnije korištenje internih informacija.

Pored troškovnog i upravljačkog računovodstva, sve se više ističe važnost integriranja koncepta društveno odgovornog računovodstva u postojeći općeprihvaćeni računovodstveni okvir. Ovime bi se postojeći sustav dopunio informacijama o društvenoj uspješnosti pojedinog poduzeća ili institucije. Ovaj koncept na središnje mjesto stavlja odgovornost prema dionicima, a potreba za implementacijom istoga se javila s obzirom da subjekti pored financijskih učinaka koje prati tradicionalan računovodstveni sustav ostvaruju i nefinancijske učinke koje on nije u mogućnosti pratiti.

Visokoobrazovni sustavi zemalja Europe posljednjih su godina suočeni s velikim promjenama. Potpisivanjem Bolonjske deklaracije zemlje potpisnice su se obvezale svoje sustave visokog obrazovanja uskladiti s načelima koja ona propisuje. Najznačajnije promjene odnose se na novu koncepciju studija koja se sastoji od tri dijela, preddiplomskog, diplomskog i poslijediplomskog studija čime bi se trebala osigurati usporedivost diploma unutar europskog prostora visokog obrazovanja. Kao ključne stavke bolonjskog procesa ističu se još uvođenje ECTS sustava, poticanje međunarodne suradnje između institucija te mobilnosti studenata, nastavnog i nenastavnog osoblja. Kako bi se unutar europskog visokoobrazovnog prostora mogle uspoređivati kvalifikacije radnika koji dolaze iz različitih zemalja, donesen je Europski kvalifikacijski okvir. On služi kao poveznica između nacionalnih kvalifikacijskih okvira različitih zemalja pri čemu se naglasak stavlja na ishode učenja. Pritom se kao svrha ističe osiguravanje kvalitete tako da se usuglase potrebe tržišta rada s ponudom kvalifikacijskih struktura.

Pitanje kvalitete sustava visokog obrazovanja i visokoobrazovnih institucija, potaknuto brojnim promjenama u visokom obrazovanju zemalja Europe, aktualiziralo se posljednjih godina. Doktorska disertacija pristupa vrednovanju kvalitete visokoobrazovnih institucija s aspekta njezine dvije temeljne sastavnice, efikasnosti i efektivnosti. Sukladno tome, postavljena su dva modela vrednovanja visokoobrazovnih institucija ekonomskog usmjerenja. Prvi, empirijski model, u funkciji je vrednovanja relativne efikasnosti, dok je drugi model teorijski te je on u funkciji vrednovanja efektivnosti.

Efikasnost i efektivnost su mjere ostvarene kvalitete i međusobno su uvjetovane. Efikasnost predstavlja mjeru na kratki rok i govori s kojom količinom inputa je ostvarena koja količina outputa. Subjekt je efikasniji kada sa što manje inputa ostvaruje što više outpute. Efektivnost predstavlja mjeru na dugi rok i podrazumijeva ostvarivanje postavljenih ciljeva. Dakle,

djelovanje subjekta, u ovom slučaju visokoobrazovne institucije ekonomskog usmjerenja trebalo bi biti takvo da istovremeno posluje i efikasno i efektivno te na taj način ostvaruje kvalitetno poslovanje.

Mjerenje efikasnosti korištenjem analize omeđivanja podataka obično se vršilo na razini sveučilišta, iako su provođene i analize na razini odjela unutar sveučilišta, pa čak i na razini visokoobrazovnog sustava države. Empirijski model vrednovanja efikasnosti prezentiran u ovom radu testiran je na primjeru 31 visokoobrazovne institucije ekonomskog usmjerenja u Republici Hrvatskoj, Sloveniji i Bosni i Hercegovini. Predmet analize su visokoobrazovne institucije ekonomskog usmjerenja iz nekoliko različitih skupina: fakulteti, odjeli sveučilišta, odjeli veleučilišta te visoke škole. Izuzev javnih, u uzorak su uključene i privatne visokoobrazovne institucije.

U doktorskoj disertaciji naglasak je stavljen na vrednovanje relativne efikasnosti visokoobrazovnih institucija ekonomskog usmjerenja. Konstruiran je model u tri faze koji predstavlja značajan odmak od tradicionalnog načina vrednovanja. Odmak se prije svega očituje u razdiobi poslovanja temeljem područja djelovanja institucije te objedinjavanja rezultata klasterizacijom gdje su identificirane grupe poslužile kao okvir za definiranje čimbenika relativno efikasnijeg ili relativno manje efikasnog poslovanja.

U prvoj fazi se analizom omeđivanja podataka utvrdio rezultat relativne efikasnosti visokoobrazovnih institucija ekonomskog usmjerenja. Postavljena su i testirana četiri različita modela. S tri modela vrednovana je relativna efikasnost promatranih institucija putem tri temeljna područja njihove djelatnosti (nastavna, znanstvena i međunarodna djelatnost) dok je četvrtim modelom vrednovana relativna efikasnost cjelokupnog poslovanja. Polazište pri izboru temeljnih područja djelovanja visokoobrazovnih institucija ekonomskog usmjerenja proizlazi iz ciljeva Bolonjske deklaracije te smjernica ESG standarda. Unutar svakog pojedinog područja identificirani su njegovi specifični inputi i outputi. Vrednovanjem je identificirano relativno efikasno i neefikasno poslovanje, utvrđeni su izvori relativne neefikasnosti za svaki pojedini model te su predložene smjernice za potencijalna poboljšanja čime je potvrđena prva pomoćna hipoteza. U drugoj fazi su, temeljem rezultata relativne efikasnosti svakog pojedinog područja, klaster analizom visokoobrazovne institucije podijeljene u skupine, odnosno klastere. Analizom su identificirana dva klastera gdje klaster 1 predstavlja skupinu visokoobrazovnih institucija ekonomskog usmjerenja koje su ostvarile bolje rezultate relativne efikasnosti u sva

tri područja djelovanja dok su u klasteru 2 grupirane one institucije koje su ostvarile slabije rezultate relativne efikasnosti u svim pojedinim područjima djelovanja. U trećoj fazi se univarijantnom binarnom logističkom regresijom utvrdila vjerojatnosti prelaska u povoljniji klaster temeljem ključnih čimbenika.

Kao ključni čimbenici pokazali su se: tip vlasništva (javno – privatno), objavljeni stručni radovi, udio ukupnih rashoda po znanstveno-nastavnom osoblju te gostujući predavači i znanstvenici. Omjer izgleda govori da je pripadnost bolje rangiranom klasteru 1 bila signifikantno viša za javne visokoobrazovne institucije ekonomskog usmjerenja, za institucije koje su objavile više stručnih radova, za institucije s višim udjelom ukupnih rashoda po znanstveno-nastavnom osoblju, za institucije s višim brojem studenata po znanstveno-nastavnom osoblju te za institucije s više gostujućih predavača i znanstvenika. Definiranje ključnih čimbenika za ostvarivanje relativno efikasnijeg poslovanja donosiocima obrazovnih politika donosi značajne informacije temeljem kojih mogu ciljano poduzeti aktivnosti za implementaciju potrebnih mjera za ostvarivanje efikasnijeg visokoobrazovnog sustava čime se potvrđuje druga pomoćna hipoteza

Pored originalnog modela, testiran je i alternativan model u kojem su stručni radovi zanemareni kao output znanstvene djelatnosti. Model je testiran kroz tri iste faze kao i onaj originalan. Nakon što je u prvoj fazi utvrđen novi rezultat relativne efikasnosti znanstvene djelatnosti, u drugoj fazi su temeljem rezultata relativne efikasnosti nastavne i međunarodne djelatnosti iz originalnog modela te znanstvene djelatnosti iz alternativnog modela klaster analizom identificirana dva klastera od kojih klaster 1 predstavlja bolje rangirane donosioce odluke, dok klaster 2 predstavlja one lošije rangirane u sva tri područja djelovanja. U trećoj fazi se je prvo Cramerovim V utvrdila povezanost između zavisne varijable (klaster 1 i klaster 2) i nezavisnih varijabli. U slučajevima nezavisnih varijabli: rashoda po znanstveno-nastavnom osoblju, studenata po znanstveno-nastavnom osoblju, gostujućih predavača i znanstvenika, znanstveno-nastavnog osoblja u zvanju docenta, izvanrednog i redovnog profesora te stručnih projekata, radi se o umjerenoj povezanosti dok je ona za varijablu javnog ili privatnog vlasništva ekstremno jaka. Daljnjom analizom se univarijantnom logističkom regresijom utvrdilo da se od spomenutih varijabli, jedino za varijablu javnog ili privatnog vlasništva sa statističkom značajnošću može utvrditi da predstavlja ključan čimbenik pripadnosti pojedinom klasteru. Omjer izgleda govori kako je pripadnost bolje rangiranom klasteru 1 signifikantno viša za javne visokoobrazovne institucije.

Na ovaj način postavljeni modeli omogućuju sveobuhvatan uvid u identificiranje čimbenika od važnosti za pripadnost određenom klasteru formiranom temeljem rezultata relativne efikasnosti svakog područja djelovanja visokoobrazovnih institucija. Rezultati empirijskog modela pružaju vrijedne informacije donositeljima odluka jer identificiraju i kvantificiraju ključne čimbenike za ostvarivanje određene razine relativne efikasnosti. Konstruiranjem teorijski utemeljenog i praktično primjenjivog empirijskog modela vrednovanja relativne efikasnosti po specifičnim područjima poslovanja i izlučivanjem ključnih čimbenika koji određuju vjerojatnost ostvarivanja određene razine relativne efikasnosti potvrđen je prvi dio temeljne znanstvene hipoteze.

Vrednovanje u području visokog obrazovanja nije stanje, nego proces koji je potrebno sustavno provoditi kako bi se osiguralo ostvarivanje ciljeva, bilo operativnih, bilo strateških. Redovito prikupljanje, obrada podataka i usporedba sa sličnim institucijama imperativ su održavanja i rasta kvalitete visokoobrazovne institucije. Kontinuiranom primjenom modela vrednovanja relativne efikasnosti visokoobrazovnih institucija ekonomskog usmjerenja mogao bi se vršiti direktan utjecaj na porast relativne efikasnosti i posljedično kvalitete institucija čime bi se potaknule brojne pozitivne implikacije kako za same institucije, tako i za visoko obrazovanje i društvo općenito. Informacija o poziciji pojedine institucije u odnosu na sebi slične omogućila bi sagledavanje o opravdanosti korištenja raspoloživih resursa, a prijedlogom mjera za poboljšanje omogućile bi se ciljane promjene u smjeru efikasnijeg poslovanja.

Teorijski model, s druge strane, je baziran na vrednovanju efektivnosti i to na način da su se oblikovale razine ostvarenja ciljeva na način da se poštuje „vertikala“. To bi konkretno značilo da se ciljevi oblikuju tako da se ciljevi nižih razina formiraju na način da budu u funkciji ciljeva viših razina. Na taj način pridonijelo bi se ostvarivanju homogenosti u području visokog obrazovanja na području Europe i omogućilo visokoobrazovnim institucijama da svoje ciljeve formiraju sa svrhom ostvarivanja zajedničkih, europskih ciljeva. Tako bi se pored homogenosti omogućilo jednostavnije efikasno poslovanje s obzirom da se kao osnovni preduvjet efikasnosti ističu ispravno formirani ciljevi, prije svega oni strateški. Također, predložen je proces unutarnjeg vrednovanja ishoda u funkciji ostvarivanja efektivnosti visokoobrazovnih institucija. Proces je definiran kroz sedam međusobno povezanih faza kojima je predložena konkretna procedura unutarnjeg vrednovanja čime je potvrđena treća pomoćna hipoteza. S obzirom na usku povezanost efikasnosti i efektivnosti kao odrednica kvalitete, u sklopu samog

procesa, u trećoj fazi se predlaže korištenje empirijskog modela konstruiranog i testiranog u doktorskoj disertaciji. Predlaganjem teorijski utemeljenog kvalitativnog modela utvrđivanja efektivnosti čijom primjenom se posljedično omogućuje unaprjeđenje kvalitete potvrđen je drugi dio temeljne znanstvene hipoteze.

Potvrđivanjem temeljne znanstvene hipoteze kao i pomoćnih hipoteza ostvarena je svrha i cilj znanstvenog istraživanja prezentiranog u doktorskoj disertaciji. Ujedno je odgovoreno na uvodno postavljena pitanja jer su definirane teorijske odrednice visokih učilišta te odrednice proračunskog, troškovnog i upravljačkog računovodstva visokih učilišta, kao i međuovisnost tih odrednica. Prikazani su načini financiranja visokih učilišta te su istražene specifičnosti visokoobrazovnog sustava s naglaskom na visokoobrazovne institucije ekonomskog usmjerenja u Hrvatskoj i zemljama regije, posebno sa stajališta Bolonjskog u odnosu na predbolonjski sustav. Također je odgovoreno na najrazličitije aspekte važnosti i vrednovanja kvalitete visokoobrazovnih institucija

Buduća istraživanja trebala bi se usmjeriti na proširenje predloženog modela na način da se u istraživanje uvedu varijable koje daju informaciju o zapošljivosti nakon završetka studija. Također se, predlaže proširenje modela na područje cjeloživotnog učenja. S obzirom na usklađenost visokoobrazovnih sustava zemalja Europe s načelima Bolonjske deklaracije, predlaže se proširiti uzorak i na druge zemlje. Pored navedenog, kao prijedlog za buduća istraživanja izdvaja se i uvođenje vremenske komponente u analizu kako bi se pratio napredak promatranih institucija. Pored empirijskog modela vrednovanja efikasnosti predložen je i okvir za vrednovanje efektivnosti koji bi u budućnosti trebao biti detaljnije razvijen i kvantitativno potvrđen.

LITERATURA

1. Abbott, M i Doucouliagos, C. (2003). The efficiency of Australian universities: a data envelopment analysis, *Economics of Education Review*, 22(1): 89-97.
2. Abd Aziz, N.A., Mohd Janor, R.M., Mahadi, R. (2013) Comparative Departmental Efficiency Analysis within a University: A DEA Approach, *Procedia - Social and Behavioral Sciences*, 90(10): 540–548
3. Academic ranking of world universities (2013). Top 500 Universities, dostupno na: <http://www.shanghairanking.com/> (7.11.2013)
4. Adler, N., Yazhemsky, E (n.d.) Improving discrimination in Data Envelopment Analysis: PCA-DEA versus Variable Reduction. Which method at what cost?, Hebrew University of Jerusalem, Working Paper of the Hebrew University Business School
5. Agasisti, T., Pérez-Esparrells, C. (2010). Comparing efficiency in a cross-country perspective: the case of Italian and Spanish state universities, *Higher Education*, 59(1), 85-103.
6. Agencija za znanost i visoko obrazovanje - AZVO (n.d.-a). Ustroj sustava visokog obrazovanja i znanosti u Republici Hrvatskoj, dostupno na: <https://www.azvo.hr/index.php/hr/visoko-obrazovanje/ustroj-sustava-visokog-obrazovanja> (20.02.2013)
7. Agencija za znanost i visoko obrazovanje – AZVO (n.d.-b). Bolonjski proces, dostupno na: <https://www.azvo.hr/hr/visoko-obrazovanje/bolonjski-proces> (14.10.2012)
8. Agencija za znanost i visoko obrazovanje – AZVO (n.d.-c). Broj studenata po poljima od akademske godine 2008/09 do 2012/13, dostupno na: <https://www.azvo.hr/hr/statistike/1122-broj-studenata-po-poljima-od-akademske-godine-2008-09-do-2012-13> (11.07.2015)
9. Agencija za znanost i visoko obrazovanje – AZVO (n.d.-d). Broj studenata na visokim učilištima od 2008/09 do 2013/14 godine, dostupno na: <https://www.azvo.hr/hr/statistike/broj-studenata-po-raznim-kriterijima/44-statistike/689-broj-studenata-na-visokim-uilitima-za-0910-i-1011-godinu> (11.07.2015)

10. Agencija za znanost i visoko obrazovanje – AZVO (2007). Pojmovnik osnovnih termina i definicija u području osiguranja kvalitete u visokom obrazovanju, Zagreb, dostupno na <http://www.unios.hr/uploads/50pojmovnik.pdf> (10.09.2013)
11. Agencija za znanost i visoko obrazovanje – AZVO (2010). Priručnik kvalitete Agencije za znanost i visoko obrazovanje, Zagreb, dostupno na: http://static.fpz.hr/kvaliteta/files/AZVO_Prirucnik_kvalitete_final.pdf (13.03.2013)
12. Agencija za znanost i visoko obrazovanje – AZVO (2013a). Visoka učilišta u Republici Hrvatskoj, dostupno na: <http://www.azvo.hr/index.php/hr/visoko-obrazovanje/visoka-ucilista> (13.03.2013)
13. Agencija za znanost i visoko obrazovanje – AZVO (2013b). dostupno na: <http://www.azvo.hr/hr/kvaliteta> (13.03.2013)
14. Agencija za znanost i visoko obrazovanje - AZVO (2013c). Shema studija u RH: dostupno na: <https://www.azvo.hr/hr/statistike/shema-studija-u-rh> (3.05.2015)
15. Aigner, D. J., Lovell, C. A. K. i P. Schmidt (1977). Formulation and Estimation of Stochastic Frontier Function Models, *Journal of Econometrics* 6: 21–37.
16. Ambrožič, M. (1999). Evaluacija knjižnica i utvrđivanje uspješnosti njihovog poslovanja Utvrđivanje uspješnosti poslovanja visokoškolskih knjižnica: od kvantitativnih do kvalitativnih pokazatelja, Doktorska disertacija. Zagreb: Filozofski fakultet
17. Andersen, P., Petersen. N. C. (1993). A Procedure for Ranking Efficient Units in Data Envelopment Analysis, *Management Science*, 39(10): 1261-1264.
18. Arbula, A. (2012). Using Data Envelopment Analysis to Evaluate the Efficiency of Higher Education Expenditure in Europe, *Journal of International Scientific Publications: Economy & Business*. 6: 59-69.
19. Aristovnik, A. (2011a). An analysis of the efficiency of education spending in central and eastern Europe, Knowledge as Business Opportunity: Proceedings of the Management, Knowledge and Learning International Conference 2011: 277-286, dostupno na: <http://www.issbs.si/press/ISBN/978-961-92486-3-8/papers/ML11-31.pdf> (5.07.2012)
20. Aristovnik, A. (2011b). Technical Efficiency of Public Education And R&D Expenditures in Selected EU and OECD Countries: A Non-Parametric Analysis,

Proceedings of 8th International Conference «Economic Integration, Competition and Cooperation», 6-9 April, Opatija, University of Rijeka – Faculty of Economics

21. Aristovnik, A., Obadić, A. (2011). The Funding and Efficiency of Higher Education in Croatia and Slovenia: A Non-Parametric Comparison, *Amfiteatru Economic*, 13(30): 362-376.
22. Arnaboldi, M., Azzone, G. (2004). Benchmarking University activities: an Italian case study, *Financial Accountability & Management*, 20(2): 205-220.
23. Athanassopoulos, A. D. i Shale, E. (1997). Assessing the comparative efficiency of higher education institutions in the UK by the means of Data Envelopment Analysis, *Education Economics*, 5(2): 117-134.
24. Badri, M., Mohaidat, J., El Mourad, T. (2014) Measuring the Efficiency of Public Schools using Data Envelopment Analysis – An Exploratory Study, *Journal of Education and Practice*, 5(37): 215-232
25. Bajo, A. (n.d.). Financiranje visokih učilišta u Hrvatskoj, Institut za javne financije, prezentacija, dostupno na: www.ijf.hr/Pdf/bajo-znanost.ppt (20.06.2011)
26. Bajo, A. (2003). Financiranje visokog školstva i znanosti, Institut za javne financije, Zagreb
27. Banker, R.D. (1984). Estimating most productive scale size using Data Envelopment Analysis, *European Journal of Operational Research*, 17(1): 35–44.
28. Banker, R. D., Charnes, A i Cooper, W.W. (1984). Some models for estimating technical and scale inefficiencies in data envelopment analysis, *Management Science*, 30(9): 1078–1092.
29. Barberić, H. (2009). Osnivanje ustanove, *Pravo i porezi, Računovodstvo, revizija i financije*, 11: 47-53.
30. Bayoud, N. S., Kavanagh, M., Slaughter, G. (2012). Factors Influencing Levels of Corporate Social Responsibility Disclosure by Libyan Firms: A Mixed Study, *International Journal of Economics and Finance*, 4(4): 13-29.

31. Bayraktar, E., Tatoglu, E., Zaim, S. (2013). Measuring the relative efficiency of quality management practices in Turkish public and private universities, *Journal of the Operational Research Society*, 64(12):1810–1830
32. Beasley, J. E. (1990). Comparing university departments, *Omega*, 18(2): 171–183.
33. Beasley, J. E. (1995). Determining teaching and research efficiencies, *Journal of the Operational Research Society*, 46(4): 441–452.
34. Bečić, M., Vojinić, M. i Stojčić, N. (2013). Zadovoljstvo studenata i kvaliteta usluge odjela za ekonomiju i poslovnu ekonomiju Sveučilišta u Dubrovniku, *Zbornik radova znanstvene konferencije: Ekonomsko obrazovanje u Republici Hrvatskoj – jučer, danas, sutra*, Zagreb
35. Beljo Lučić, R. i dr. (2009). Hrvatski kvalifikacijski okvir - Uvod u kvalifikacije, Vlada Republike Hrvatske, Ministarstvo znanosti, obrazovanja i športa, Zagreb, Dželalija, M. (ur.)
36. Benazić, A. (2012). Measuring efficiency in the Croatian customs service: a data envelopment analysis approach, *Financial Theory and Practice*, 36(2): 139-173.
37. BFUG Working Group on Stocktaking (2005). Bologna Process Stocktaking. Report from a working group appointed by the Bologna Follow-up Group to the Conference of European Ministers Responsible for Higher Education, Bergen, 19-20 May 2005, dostupno na: <http://www.ond.vlaanderen.be/hogeronderwijs/bologna/documents/BPStocktaking9May2005.pdf> (13.11.2013)
38. Bogetoft, P. i Otto, L. (2011). Benchmarking with DEA, SFA, and R, *International Series in Operations Research & Management Science*, Vol. 157, Springer Science+Business Media
39. Branković, J., Branković, N. (2013). Overview of Higher Education and Research Systems in the Western Balkans: Bosnia and Herzegovina, dostupno na: http://www.herdata.org/public/HE_and_Research_in_BiH_FINAL.pdf (11.07.2015)
40. Briggs P. D., Sullins, W.R. (1982). Cost-Benefit Analysis: Applicability in Higher Education, *Journal of Education Finance*, 8(1): 20-32

41. Brovender, S. (1974). On the Economics of a University: Toward the Determination of Marginal Cost of Teaching Services, *Journal of Political Economy*, 82(3): 657-664.
42. Budimir, V. (2006). Značaj računovodstvenih informacija u analizu uspješnosti ustanova visokog obrazovanja u Republici Hrvatskoj, Magistarski rad, Zagreb, Ekonomski fakultet
43. Budimir, V. (2010). Mjerenje uspješnosti poslovanja proračunskih korisnika, *Riznica*, 56(7): 14-21
44. Cabrera, A. F. (1994). Logistic Regression Analysis in Higher Education: An Applied Perspective, u J.C. Smart (ur.): Higher Education, Handbook of Theory and Research, vol. 10: 225-256, Agathon Press, New York
45. Cañas, A. J., Novak, J. D.: Why the Focus Question?, Institute for Human and Machine Cognition, 2009, dostupno na: <http://cmap.ihmc.us/docs/focusquestion.html> (7.08.2010)
46. Centar za informiranje i priznavanje dokumenata iz područja visokog obrazovanja (CIP) (n.a.). dostupno na: <http://www.cip.gov.ba/>
47. Cerović, Lj., Arbula, A., (2012). Razumne granice vrednovanja sustava visokog ekonomskog obrazovanja, *Zbornik sažetaka znanstvene konferencije: Ekonomsko obrazovanje u Republici Hrvatskoj – jučer, danas, sutra*, Zagreb, 38-40.
48. Cerović, Lj., Arbula Blečić A. i Štambuk, A. (2014). Relevant Areas and Indicators of Quality in Higher Education Institutions: Evaluating the System of Higher Education in Economics, *Management: Journal of Contemporary Management Issues*, 19(2): 89-116.
49. Casu, B. i E. Thanassoulis (2006). Evaluating cost efficiency in central administrative services in UK universities, *Omega*, 34(5): 417–426.
50. Centre for the Study of Higher Education Management (CEGES), Valencia University of Technology (2007). Rates of return and funding models in Europe. Study requested by the European Commission, Directorate-General Education and Culture.
51. Charnes, A. i dr. (1989). Cone ratio data envelopment analysis and multi-objective programming, *International Journal of Systems Science*, 20(7), 1099–1118.
52. Charnes, A, Cooper, WW i Rhodes, E (1978). Measuring the efficiency of decision making units, *European Journal of Operational Research*, 2(6): 429-444.

53. Cherchye, L., Vanden Abeele, P. (2005). On research efficiency: a microanalysis of Dutch university research in economic and business management, *Research Policy*, 34(4): 495–516.
54. Coelli, T. J. (1996). Assessing the Performance of Australian Universities using Data Envelopment Analysis. Australia, Centre for Efficiency and Productivity Analysis, University of New England
55. Cohn, E., Rhine, S. L. W., Santos, M.C. (1989). Institutions of Higher Education as Multi-product Firms: Economies of Scale and Scope, *The Review of Economics & Statistics*, 71(2): 284-290.
56. Cooper, W. W., Seiford, L. M. i Tone, K. (2007). Data Envelopment Analysis - A Comprehensive Text with Models, Applications, References and DEA-Solver Software, Second edition, Springer Science+Business Media, LLC
57. Cornish, R. (2007). Statistics, poglavlje 3.1. Cluster analysis, Mathematics learning support centre, dostupno na: <http://www.statstutor.ac.uk/resources/uploaded/clusteranalysis.pdf> (3.07.2015)
58. Ćukušić, M. (2011). Procesna organizacija i uspješnost visokih učilišta, istraživanje u sklopu izrade doktorske disertacije, Ekonomski fakultet Sveučilišta u Splitu
59. Ćukušić, M., Garača, Ž., Jadrić, M. (2014). Odrednice i pokazatelji uspješnosti visokih učilišta u Hrvatskoj, *Društvena istraživanja*, 23(2): 233-257.
60. de Groot, H., McMahon, W. W., Volkwein, J. F. (1991). The Cost Structure of American Research Universities, *The Review of Economics and Statistics*, 73(3): 424-431.
61. de la Fuente, A. i Jimeno, J. F. (2005). The private and fiscal returns to schooling and the effect of public policies on private incentives to invest in education: a general framework and some results for the EU, CESifo Working Paper, 1392.
62. Dearden, L. (1998). Ability, family, education and earnings in Britain, Institute of Fiscal Studies, Working Paper, No. 14
63. Devčić, K., Tonković, Pražić, I., Župan, Ž. (2012). Klaster analiza: primjena u marketinškim istraživanjima, *Zbornik radova Međimurskog veleučilišta u Čakovcu*, 3(1):15-22.

64. Dimitrić, M. (2007). Računovodstvo rashoda javnog sektora na mikro i makro razini, *Zbornik referata konferencije "Hrvatski javni sektor"*, HZRIF, Zagreb
65. Dolček – Alduk, Z., Sigmund, V., Lončar – Vicković, S. (2008). Osiguranje kvalitete visokog obrazovanja u europskom obrazovnom prostoru, *Tehnički vjesnik*, 15(1): 39-44
66. Domović, V. (2003). Efektivnost škole - kako ju procjenjivati? Didaktični in metodični vidiki prenovе in razvoja izobraževanja: knjiga referatov z 2. mednarodnega znanstvenega posveta / Kramar, Martin ; Duh, Matjaž (ur.). - Maribor, Slovenija : Pedagoška fakulteta Maribor
67. Dragija, M., Letica, M. (2014). ABC metoda - adekvatna tehnika u reformi sustava financiranja visokog obrazovanja?, *Zbornik Ekonomskog fakulteta u Zagrebu*, 12(1): 79-97
68. Dražić Lutilsky, I. (2006). Informacije o troškovima u funkciji upravljanja javnim sektorom, Ekonomski fakultet Sveučilišta u Zagrebu, doktorska disertacija
69. Dražić Lutilsky, I., Broz Tominac, S. (2013). Pokazatelji uspješnosti na visokoškolskim ustanovama, *Zbornik radova znanstvene konferencije: Ekonomsko obrazovanje u Republici Hrvatskoj – jučer, danas, sutra*, Zagreb
70. Dundar, H., Lewis, D. R. (1995). Departmental Productivity in American Universities: Economies of Scale and Scope, *Economics of Education Review*, 14(2): 119-144.
71. Drucker, P. (2006). *The Effective Executive: The Definitive Guide to Getting the Right Things Done*, Harper Business; Revised edition
72. Državni zavod za statistiku Republike Hrvatske (DZS) (2015): Istraživanje i razvoj u 2013., Statistička izvješća
73. Dyson, R. G. i Thanassoulis, E. (1988). Reducing weight flexibility in data envelopment analysis, *Journal of the Operational Research Society*, 39: 563–576.
74. Dželalija, M., Hrvatski kvalifikacijski okvir (CROQF, HKO) (2007), CARDS 2003: Furtherance of the Agency of Science and Higher Education in its Quality Assurance Role and the Development of a Supporting Information System, Ministarstvo znanosti, obrazovanja i sporta, dostupno na: http://forum.azvo.hr/cd/LinkedDocuments/Dzelalija_CROQF_Bjelolasica%20-%20presentation.pdf (10.09.2011)

75. Eckles, J. E. (2010). Evaluating the efficiency of top liberal arts colleges, *Research in Higher Education*, 51(3), 266-293.
76. ENQA (n.d.), dostupno na: www.enqa.net (20.04.2014)
77. ENQA (2009): Standards and Guidelines for Quality Assurance in the European Higher Education Area - 3rd edition (ESG), dostupno na http://www.eqar.eu/fileadmin/documents/e4/050221_ENQA_report.pdf (16.04.2013.)
78. Entwistle, N. J., Brennan, T. (1971). The academic performance of students. 2. Types of successful student. *British Journal of Educational Psychology*, 41(3): 268-276.
79. Eerma, D., Friedrich, P. i Mošnja – Škare, L. (2012). Standardni okvir društveno odgovornog računovodstva – mogućnosti integracije u tradicionalni računovodstveni sustav institucija visokog obrazovanja, *Ekonomski misao i praksa*, 21(1): 279-314.
80. European University Association – EUA (n.d.). Quality Culture Project 2002 – 2006, dostupno na: <http://www.eua.be/eua-work-and-policy-area/quality-assurance/projects/quality-culture-project.aspx> (16.04.2013.)
81. European Commission (2011). Communication from the Commission to the European parliament, the Council, the European economic and social committee and the Committee of the regions, Supporting growth and jobs – an agenda for the modernisation of Europe's higher education systems, dostupno na: <http://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:52011DC0567&from=EN> (5.04.2014)
82. European Commission (n.d.). Efficiency and effectiveness of public expenditure on tertiary education in the EU, Joint Report by the Economic Policy Committee (Quality of Public Finances) and the Directorate-General for Economic and Financial Affairs, Working Document (Forthcoming European Economy Occasional Papers No 70)
83. Eurostat (2014). Expenditure on education as % of GDP or public expenditure, dostupno na: http://appsso.eurostat.ec.europa.eu/nui/submitViewTableAction.do?sessionId=KRuRjC1XoDV5KZazM_CTawARqJQtvdzxUQBTKBGpYyGKMijqROJt!1846957472 (10.07. 2015)

84. Eurostat (2015a): Gross domestic expenditure on R&D (GERD) by source of funds, % of total GERD, dostupno na: <http://epp.eurostat.ec.europa.eu/tgm/refreshTableAction.do?tab=table&plugin=1&pcode=tsc00031&language=en> , pregledano (15.07.2015)
85. Eurostat (2015b): Research and development expenditure, by sectors of performance % of GDP dostupno na: <http://ec.europa.eu/eurostat/tgm/table.do?tab=table&init=1&language=en&pcode=tsc00001&plugin=1> (15.07.2015)
86. Farneti, F., Guthrie, J. (2008). GRI Sustainability Reporting by Australian Public Sector Organizations, *Public Money & Management*, 28(6):345-352
87. Filozofski fakultet Sveučilišta u Zagrebu (n.d.). Primjena multivarijantnih metoda, Klasterni analiza, dostupno na: http://www.ffzg.unizg.hr/psiho/phm/nastava/pmm/KLASTER_ANALIZA_PREZENTACIJA.PPT (3.06.2015)
88. Flegg, A.T. Allen, D.O., Field, K, Thurlow, T.W. (2003). Measuring the Efficiency and Productivity of British Universities: An Application of DEA and the Malmquist Approach, University of the West of England, Department of Economics, series Discussion Papers No. 04.
89. Førsund, F.R. (2002). Categorical variables in DEA, *International Journal of Business and Economics*, 1(1): 33-44
90. Friedrich, P., Feng, X., Jahn, K., Valjak, G., Wonnemann, H.G. (2000). Economic Effects of Locating Tourist Facilities, in: *Tourism Sustainability and Territorial Organisation*, APDR (Hrsg.), Coimbra, S., p. 143-174. prema: Erma, D., Friedrich, P. i Mošnjica – Škare, L. (2012). Standardni okvir društveno odgovornog računovodstva – mogućnosti integracije u tradicionalni računovodstveni sustav institucija visokog obrazovanja, *Ekonomski misao i praksa*, 21(1): 279-314.
91. García-Aracil, A., Palomares-Montero, D. (2008) Evaluation of Spanish Universities: Efficiency, Technology and Productivity Change. Paper presented in the Prime-Latin America Conference at Mexico City, September 24-26th 2008.
92. Giménez, V. M. i Martínez, J. L. (2006). Cost Efficiency in the University: A Departmental Evaluation Model, *Economics of Education Review*, 25(5): 543-553.

93. Gray, R. (2001). Thirty years of social accounting, reporting and auditing: what (if anything) have we learnt?, *Business Ethics: A European Review*, 10(1): 9-15.
94. Gray, R., Dey, C., Owen, D., Evans, R., Zadek, S. (1997). Struggling with the praxis of social accounting: Stakeholders, accountability, audits and procedures, *Accounting, Auditing & Accountability Journal*, 10(3):325-364
95. Guisan, M. C., Aguayo, E. i Exposito, P. (2001). Economic Growth and Cycles: Cross-Country Models of Education, Industry and Fertility and International Comparisons, *Applied Econometrics and International Development*. 1(1): 1-18, dostupno na: <http://www.usc.es/~economet/reviews/aeid111.pdf> (25.09.2011)
96. Gujarati, D.N., Porter, D.C. (2009). Basic Econometrics, fifth edition, McGraw-Hill Higher Education
97. Hanson, G. R., Swann, D. M. (1993) Using multiple program impact analysis to document institutional effectiveness, *Research in Higher Education*, 34(1):71-94.
98. Horne, J., Hu, B. (2008). Estimation of cost efficiency of Australian universities, *Matematics and Computers in Simulation*, 78(2-3): 266-275.
99. Hosseinzadeh Saljooghi, F., Mahallati Rayeni, M. (2011). Distinguishing Congestion and Technical Inefficiency in presence Undesirable Output, *American Journal of Applied Sciencies* 8(9): 903-909.
100. Hunjak, T. (2008). Financiranje visokih učilišta. Bajo, A. (ur.) Financiranje visokih učilišta: Troškovi studija i školarine na hrvatskim visokim učilištima, Zagreb: Institut za javne financije, p. 91-104.
101. Hsuan-Fu H., Chia-Chi H. (2008). Marketing mix formulation for higher education: An integrated analysis employing analytic hierarchy process, cluster analysis and correspondence analysis, *International Journal of Educational Management*, 22(4): 328 - 340
102. Institut za javne financije (2003). Proračunski vodič za građane, Pojmovnik, dostupno na: <http://www.ijf.hr/proracunski/2009.pdf> (7.07. 2011)

103. Institut za javne financije (2010). Analiza sustava zaposlenih u hrvatskom javnom sektoru, Istraživački projekt, dostupno na: <http://www.nsz.hr/datoteke/09-10/Analiza%20sustava%20zaposlenih.pdf> (4.03. 2012)
104. IFAC-PSC (2000). Study 12 Perspectives in Cost Accounting for Government. New York: IFAC-PSC, prema Vašiček, D i dr. (2011). Upravljačko računovodstvo i računovodstvo troškova u javnom sektoru- izabrane teme, Vašiček, V., Dragija, M. (ur.), Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb
105. Institut za razvoj obrazovanja – IRO (2015). Studiranje u Hrvatskoj, Pregled institucija, dostupno na: <http://www.iro.hr/hr/informiranje-i-savjetovanje-o-visokom-obrazovanju/studiranje-u-hrvatskoj/pregled-institucija/> (17.05. 2015)
106. Institut za razvoj obrazovanja - IRO (2010a). Model financiranja visokog obrazovanja: primjeri prakse u devet zemalja Europske unije, Institut za razvoj visokog obrazovanja, Zagreb
107. Institut za razvoj obrazovanja - IRO (2010b). Model financiranja visokog obrazovanja u Hrvatskoj, Institut za razvoj visokog obrazovanja, Zagreb
108. Ivković, M. (2009). Osiguranje kvalitete u visokom obrazovanju, *Ekscentar*, 64(11): 20-23.
109. Jafarov, E., Gunnarsson, V. (2008). Efficiency of Government Social Spending in Croatia, *Financial Theory and Practice*, 32(3): 289-320.
110. Jahanshaloo, G. R., Rostami Malkhalifeh, M., Hosseinzadeh Lofti, F. Mohsenpour, Z. (2012). Measuring the Efficiency and Congestion of Iranian Airports in 2008 with Data Envelopment Analysis, *Journal of Basic and Applied Scientific Research*, 2(12): 12354-12358
111. Jakir – Bajo, I. (2003). Mjerenje uspješnosti u hrvatskom javnom sektoru, *Računovodstvo, revizija i financije*, br. 8
112. James, E. (1978). Product Mix and Cost Disaggregation: A Reinterpretation of the Economics of Higher Education, *Journal of Human Resources*, 13(2): 157-186.
113. Jarić, I., Vukasović, M. (2009). Bolonjska reforma visokog školstva u Srbiji: mapiranje faktora niske efikasnosti studiranja, *Filozofija i društvo*, 20(2):119-151.

114. Johnes, G., Johnes, J. (2009). Higher education institutions' costs and efficiency: taking the decomposition a further step, *Economics of Education Review*, 28(1):107-113.
115. Johnes, G., Johnes, J., Thanassoulis, E. (2008). An analysis of costs in institutions of higher education in England, *Studies in Higher Education*, 33(5):527-549.
116. Johnes, J. (2006). Data envelopment analysis and its application to the measurement of efficiency in higher education, *Economics of Education Review*, 25(3): 273–288
117. Johnes, J. (2008). Efficiency and productivity change in the English higher education sector from 1996/97 to 2004/5, *The Manchester School*, 76(6), 653-674.
118. Johnes, J., Bradley, S., Little, A. (2012). Efficiency in the Further Education Sector in England, *Open Journal of Statistics*, 2(1): 131-140.
119. Johnes, J., Yu, L. (2008). Measuring the research performance of Chinese higher education institutions using data envelopment analysis, *China Economic Review*, 19(4): 679-696.
120. Jurlina Alibegović, D., Sljepčević, S. (2012). Identifying Key Obstacles for Performance Measurement at the Sub-National Level in Croatia, *Croatian and comparative public administration*, 12(4): 1117 – 1156.
121. Kantabutra, S. i Tang, J. C. S. (2010). Efficiency analysis of public universities in Thailand, *Tertiary Education and Management*, 16(1), 15-33.
122. Kaplan, R.S., Norton, D.P. (1992). The Balanced Scorecard: Measures that Drive Performance, *Harvard Business Review*, 70(1): 71–79.
123. Katedra za psihometriju (n.d.). Klaster analiza, dostupno na: http://www.ffzg.unizg.hr/psiho/phm/nastava/pmm/KLASTER_SAZETAK_PREDAVANJA_ZA_STUDENTE.DOC (7.06.2015)
124. Keser, J. i dr. (2000) Sustav proračuna, Računovodstvo, financije, revizija, porezi, HZRFD, Zagreb
125. Kesner-Škreb, M. (n.d.). Javne financije, Korisne informacije: Pojmovnik javnih financija, dostupno na: <http://www.ijf.hr/hr/korisne-informacije/pojmovnik-javnih-financija/15/javne-financije/43/javne-financije/327/> (17.03.2013)

126. Korhonen, P., Tainio, R., Wallenius, J., (2001). Value efficiency analysis of academic research, *European Journal of Operational Research* 130(1): 121–132.
127. Kovačević, Z. i Sisek, B. (2007). Financing of higher education in the Republic of Croatia, *Poslovna izvrsnost*, Zagreb, 1(1): 139-155.
128. Koshal, R. K., M. Koshal, Gupta, A. (2001). Multi-product total cost function for higher education: a case of bible colleges, *Economics of Education Review*, 20(3): 297–303.
129. Kostić, P., Hedrih, V. (2005). Psihološka računarska statistika v0.3, poglavlje Klaster analiza, dostupno na: www.hm.co.rs/statistika/knjiga/Statmatalat.doc
130. Krištof, M., Pisk, K., Radeka, I. (2011). Istraživanje o primjeni Bolonjskog procesa na hrvatskim sveučilištima, dostupno na: http://www.nsz.hr/novosti-i-obavijesti/vijesti_iz_znanosti_i_obrazovanja/istrazivanje-o-primjeni-bolonjskog-procesa-na-hrvatskim-sveucilistima/ (20.02.2013)
131. Küpper, H.-U. (2013): A specific accounting approach for public universities, *Journal of Business Economics*, 83(7): 805-829.
132. Laband, D. N., Lentz, B. F. (2003). New Estimates of Economies of Scale and Scope in Higher Education, *Southern Economic Journal*, 70(1): 172-183.
133. Lazibat, T., Sutić, I., Baković, T. (2013). Istraživanje percepcija studenata o kvaliteti visoko obrazovne usluge na ekonomskim visoko obrazovnim institucijama u Republici Hrvatskoj, *Zbornik radova znanstvene konferencije: Ekonomsko obrazovanje u Republici Hrvatskoj – jučer, danas, sutra*, Zagreb
134. Lazibat, T., Sutić, I., Jurčević, M. (2009). Quality Management System at The Faculty of Economics and Business, 31st Annual EAIR Forum in Vilnius, Lithuania
135. Leko Šimić, M., Štimac, H. (2013). Kvaliteta obrazovne usluge – slučaj Ekonomskog fakulteta u Osijeku, *Zbornik radova znanstvene konferencije: Ekonomsko obrazovanje u Republici Hrvatskoj – jučer, danas, sutra*, Zagreb
136. Liu, C.-Y. A., Tsai, C.-C. K. (2014). Evaluation on Higher Education Using Data Envelopment Analysis, *International Journal of Management Excellence*, 4(2): 522-528

137. Maletić, I., Jakir-Bajo, I. (2005). Primjena proračunskog računovodstva u ustanovama u djelatnosti znanosti i visokog obrazovanja, *Računovodstvo, revizija i financije*, br. 7
138. Mandić, M., Pavlović, A. (2013). Istraživanje očekivanja i zadovoljstva studenata diplomskog studija smjera marketing, *Zbornik radova znanstvene konferencije: Ekonomsko obrazovanje u Republici Hrvatskoj – jučer, danas, sutra*, Zagreb
139. Mar Molinero, C. (1996). On the joint determination of efficiencies in a data envelopment analysis context, *Journal of the Operational Research Society*, 47(10): 1273–1279.
140. Martinuzzi, A., Krumay, B., Pisano, U. (2011). Focus CSR: The New Communication of the EU Commission on CSR and National CSR Strategies and Action Plans, ESDN (European Sustainable Development Network) Quarterly Report N°23
141. Mastilica, M. (n.d.). Uvod u management i uloge managera, dostupno na: sharepoint.zvu.hr/katedre/318/.../management-Mastilica.ppt (5.06.2013)
142. Mathews, M.R. (1993), *Socially Responsible Accounting*, Chapman and Hall, London. (iz Mathews, M.R. (1997). Twenty-five years of social and environmental accounting research Is there a silver jubilee to celebrate?, *Accounting, Auditing & Accountability Journal*, 10(4): 481-531.
143. Mathews, M.R. (1997). Twenty-five years of social and environmental accounting research Is there a silver jubilee to celebrate?, *Accounting, Auditing & Accountability Journal*, 10(4): 481-531.
144. Meeusen, W., Van den Broeck, J. (1977). Efficiency Estimation from Cobb-Douglas Production Functions with Composite Errors, *International Economic Review*, 18(2), 435–444
145. McMillan, M. L., Datta, D. (1998). The Relative Efficiencies of Canadian Universities: A DEA Perspective, *Canadian Public Policy – Analyse de politiques*, 24(4): 485-511.
146. Mihalić, M. (2012). Mjere li samo pokazatelji uspješnosti vrijednost knjižnica? : Prema vrednovanju društvenih ciljeva organizacija u kulturi, *Vijesnik bibliotekara hrvatske*, 55(1): 29-44.
147. Ministarstvo financija Republike Hrvatske (MFIN) (n.d.). Državna riznica, dostupno na: <http://www.mfin.hr/hr/drzavna-riznica> (13.09.2013)

148. Ministarstvo financija Republike Hrvatske (MFIN) (2007). Strategija unapređenja i modernizacije procesa u sustavu državne riznice 2007.– 2011., dostupno na: http://www.mfin.hr/adminmax/docs/strategija2007_hr.pdf (13.09.2013)
149. Ministarstvo financija Republike Hrvatske (MFIN) (2013). Temeljni financijski izvještaji javnih visokih učilišta u periodu od 2009. – 2012.u periodu od 2009. – 2012.
150. Ministarstvo prosvete, nauke i tehnološkog razvoja (mpn) (2015). Visoko obrazovanje, dostupno na: <http://www.mpn.gov.rs/prosveta/visoko-obrazovanje/> (15.04.2015)
151. Ministarstvo za izobražavanje, znanost in šport (MIZŠ) (2011). Higher education in Slovenia, CMEPIUS, Centre of the Republic of Slovenia for Mobility and European Educational and Training Programmes, dostupno na: www.euroeducation.net/prof/slnco.htm (14.03.2015)
152. Ministrstvo za izobraževanje znanost in šport (MIZŠ) (n.d.). dostupno na: <http://www.mizs.gov.si/en/>
153. Ministarstvo znanosti, obrazovanja i sporta (MZOS) (n.d). Znanost u Hrvatskoj pred ulazak u EU, dostupno na: public.mzos.hr/lgs.axd?t=16&id=19195 (12.04.2013)
154. Ministarstvo znanosti, obrazovanja i sporta (MZOS) (2008). Akcijski plan za poticanje ulaganja u znanost i istraživanje, Zagreb, , dostupno na: public.mzos.hr/fgs.axd?id=14917 (14.03.2013)
155. Ministarstvo znanosti, obrazovanja i športa (2007). Bologna Stocktaking Report Croatia, Zagreb, dostupno na: http://www.ond.vlaanderen.be/hogeronderwijs/bologna/documents/WGR2007/Stocktaking_report2007.pdf (5.09.2012)
156. Ministarstvo znanosti, obrazovanja i športa (2004 - 2012). Bolonjski proces i Europski prostor visokog obrazovanja, dostupno na: <http://public.mzos.hr/Default.aspx?sec=2268> (20.02.2013)
157. Ministarstvo znanosti, obrazovanja i sporta (MZOS) (2012a). Nacrt prijedloga zakona o hrvatskom kvalifikacijskom okviru, Zagreb, dostupno na: www.mzos.hr
158. Ministarstvo znanosti, obrazovanja i sporta (MZOS) (2012b). Strateški plan za razdoblje 2013.-2015., Republika Hrvatska, dostupno na: www.mzos.hr

159. Ministarstvo znanosti, obrazovanja i sporta (MZOS) (2013a). Prijedlog zakona o izmjenama i dopunama zakona o znanstvenoj djelatnosti i visokom obrazovanju, Zagreb
160. Ministarstvo znanosti, obrazovanja i sporta (MZOS) (2013b). Zakon o Hrvatskom kvalifikacijskom okviru, dostupno na: <http://www.kvalifikacije.hr/dokumenti-i-publikacije> (14.04.2015)
161. Ministarstvo znanosti, obrazovanja i sporta (MZOS) (n.d). dostupno na: www.mzos.hr
162. Mishra, S. (2007). Quality Assurance in Higher Education, National Assessment and Accreditation Council, National Assessment and Accreditation Council, Bangalore; Commonwealth of Learning, Vancouver, http://www.col.org/SiteCollectionDocuments/PUB_QAHE_Intro.pdf (7. 09. 2012.)
163. Mooi, E., Sarstedt, M. (2011). A Concise Guide to Market Research, Springer Berlin Heidelberg
164. Murias, P., de Miguel, J. C., Rodríguez, D. (2008). A Composite Indicator for University Quality Assesment: The Case of Spanish Higher Education System, *Social Indicators Research*, 89(1): 129-146.
165. Nacionalna zaklada za znanost, visoko školstvo i tehnologijski razvoj Republike Hrvatske (2007). Kvaliteta u visokom obrazovanju, Lučin, P. (ur.), dostupno na: http://www.hrzz.hr/docs/pub/nzz-kvaliteta_za_web.pdf (7. 09. 2012.)
166. Nunamaker, T.R. (1985). Using Data Envelopment Analysis to Measure the Efficiency of Non-Profit Organisations: A Critical Evaluation. *Managerial and Decision Economics*, 6(1): 50-58.
167. Organisation for Economic Cooperation and Development (OECD) (2012 – 2014). Education at a Glance Report 2007 -2011, Paris
168. Ozcan, Y.A. (2008). Health care benchmarking and performance evaluation: an assessment using data envelopment analysis (DEA), Springer, New York.
169. Peduzzi, P., Concato, J., Kemper E., Holford T.R., Feinstein A.R. (1996). A simulation study of the number of events per variable in logistic regression analysis, *J Clin Epidemiol.*, 49(12):1373-1379.

170. Peng, C.-Y. J., So, T.-S. H., Stage, F. K., St. John, E. P. (2002). The use and interpretation of logistic regression in higher education journals: 1988–1999, *Research in Higher Education*, 43(3): 259-293.
171. Podatci iz registra proračunskih i izvanproračunskih korisnika za 2015. godinu, Ministarstvo financija (NN 73/14)
172. Polšek, D. (2004). Visoko školstvo u Hrvatskoj i zahtjevi Europske unije, u: Pridruživanje Hrvatske Europskoj Uniji II, (ur.) Katarina Ott, Institut za javne financije, Friedrich Ebert Stiftung, Zagreb
173. Popović, Ž., Vitezić, N. (2009). Revizija i analiza – instrumenti uspješnog donošenja poslovnih odluka, Hrvatska zajednica računovođa i financijskih djelatnika, Zagreb
174. Pravilnik o mjerilima i načinu korištenja prihoda javnih visokih učilišta i javnih znanstvenoistraživačkih instituta ostvarenih na tržištu od obavljanja svoje djelatnosti, Ministarstvo financija (NN 92/94)
175. Pravilnik o osnovama financiranja visoke naobrazbe na javnim visokim učilištima (NN br. 25/1996 i 28/1999)
176. Pravilnik o proračunskom računovodstvu i računskom planu (NN 87/08, 136/12, 124/14)
177. Pravilnik o financijskom izvještavanju u proračunskom računovodstvu (87/08 i 136/12)
178. Pravilnik o proračunskim klasifikacijama (NN 26/10, 120/13)
179. Psacharopoulos, G. (2014). Benefits and Costs of the Education Targets for the Post-2015 Development Agenda, Post-2015 Consensus, Copenhagen Consensus Center, dostupno na: http://www.copenhagenconsensus.com/sites/default/files/education_assessment_-_psacharopoulos_0.pdf (9.05.2015)
180. Pursglove, J., Simpson, M. (2007). Benchmarking the performance of English universities, *Benchmarking: An International Journal*, 14(1):102-122.
181. Pyke, S. W., Sheridan, P. M. (1993). Logistic regression analysis of graduate student retention, *The Canadian Journal of Higher Education*, 23(2): 43-64.

182. QS Top Universities, Worldwide university rankings, guides and events (2013). QS World University Rankings, dostupno na Top Universities, Worldwide university rankings, guides and events, dostupno na: <http://www.topuniversities.com/> (6.11.2013)
183. Rabar, D. (2010). Ocjenjivanje efikasnosti poslovanja hrvatskih bolnica metodom analize omeđivanja podataka, *Ekonomski pregled*, 61(9-10): 511-533.
184. Rabar, D., Blažević, S., (2011). Ocjenjivanje efikasnosti hrvatskih županija u turizmu primjenom analize omeđivanja podataka, *Privredna kretanja i ekonomska politika*, 21(127): 25-55.
185. Ramanathan, K. V. (1976). *The Accounting Review*, 51(3): 516-528
186. Ramanathan, R. (2003). An Introduction to Data Envelopment Analysis – A Tool for Performance Measurement, Sage publications
187. Ranking web of universities „Webometrics“ (2013). dostupno na: <http://www.webometrics.info/> (7.11.2013)
188. Robst, J. (2001): Cost Efficiency in Public Higher Education Institutions, *The Journal of Higher Education*, 72(6): 730-750.
189. Ryerson University (n.d.). Tutorial in DEA, dostupno na: <http://www.ryerson.ca/~mhababou/DEAtutorial/deatutorial.html> (4.09.2013)
190. Sagarra, M., Agasisti, T., Mar Molinero, C. (2014) Exploring the efficiency of Mexican universities: integrating Data Envelopment Analysis and Multidimensional Scaling, SSRN, dostupno na: http://papers.ssrn.com/sol3/papers.cfm?abstract_id=2511321
191. Salerno, C. (2006). Using Data Envelopment Analysis to Improve Estimates of Higher Education Institution's Per-student Education Costs, *Education Economics*, 14(3): 281–295.
192. Slijepčević, S. (2010). Efikasnost i učinkovitost javne uprave: Hrvatska na putu prema Europskoj uniji, V. međunarodni simpozij "Institucionalni okvir i realne pretpostavke za reformu financijskog sustava BiH sukladno standardima (zahtjevima) Europske komisije", Mišić, A. (ur). - Mostar : Fircon d.o.o. Mostar

193. Sopek, P. (2011). Efikasnost javne potrošnje za obrazovanje u Hrvatskoj, *Povremeno glasilo instituta za javne financije*, Institut za javne financije, 61: 1-12
194. Sopek, P. (2012). Efficiency of Public Expenditure on Education in Croatia, The young economists' seminar to 18th Dubrovnik Economic Conference, Dubrovnik
195. State Secretariat for Education, Research and Innovation (SERI) i Rectors' Conference of the Swiss Universities (CRUS) (2013). Ranking methodology: How are universities ranked?, dostupno na: <http://www.universityrankings.ch/> (14.11.2013)
196. SNA - A System of National Accounts, United Nations, New York, 1993 prema: Dimitrić, M. (2007). Računovodstvo rashoda javnog sektora na mikro i makro razini, *Zbornik referata konferencije "Hrvatski javni sektor"*, HZRIF, Zagreb
197. Sveučilište u Rijeci (2012). Uspješnost provedbe Bolonjskog procesa na Sveučilištu u Rijeci, Sveučilište u Rijeci – Rektorat
198. Sveučilište u Zagrebu (2012). Samoanaliza i dokumentacija za postupak vanjske neovisne prosudbe sustava osiguravanja kvalitete Sveučilišta u Zagrebu
199. Šćukanec, N., (2010). Nastanak zajedničke visokoobrazovne politike na razini Europske unije, Institut za razvoj obrazovanja, Zagreb
200. Šegota, A. (2003). Usporedna analiza efikasnosti prodajnih objekata u maloprodaji, doktorska disertacija, Sveučilište u Zagrebu, Ekonomski fakultet Zagreb
201. Šegota, A. (2008). Evaluating shops efficiency using data envelopment analysis: Categorical approach, *Zbornik radova Ekonomskog fakulteta u Rijeci: časopis za ekonomsku teoriju i praksu*, 26(2): 325-343.
202. Šlaus, I., Šlaus – Kokotović, A., Morović, J. (2004). Education in countries in transition facing globalization – a case study Croatia, *International Journal of Educational Development*, 24(5): 479 – 493.
203. Španiček, Đ. (2005). Bolonjski proces u Hrvatskoj, *Sveučilište, Polimeri: časopis za plastiku i gumu*, 26(2): 76-78.

204. Šporčić, M. Martinić, I. Landekić, M. Lovrić, M. (2008). Analiza omeđivanja podataka kao metoda efikasnosti – mogućnosti primjene u šumarstvu, *Nova mehanizacija šumarstva*, 29(1): 51-59.
205. Šporčić, M. Martinić, I., Šegotić, K. (2007). Ocjena efikasnosti radnih jedinica u šumarstvu analizom omeđivanja podataka, *Nova mehanizacija šumarstva*, 28(1): 3-14.
206. Šporčić, M., Šegotić, K., Martinić, I. (2006). Efikasnost prijevoza drva kamionskim skupovima određena analizom omeđivanja podataka, *Glasnik za šumske pokuse* (0352-3861) 5: 679-691.
207. Štifanić, E. (2012). Izvještavanje društveno odgovornih poslovnih subjekata – stanje, smjernice i implikacije na rezultate poslovanja, *Računovodstvena obzorja*, (ur.) Mošnja – Škare, L. , HZRIF – Udruga računovođa i financijskih djelatnika Istre, Pula
208. Thanassoulis, E., Kortelainen, M., Johnes, G., Johnes, J. (2011). Costs and Efficiency of Higher Education Institutions in England: A DEA Analysis, *Journal of the Operational Research Society*, 62(7): 1282-1297.
209. The University of Texas at Austin (2013). Handbook for Institutional Effectiveness, dostupno na: <http://www.utexas.edu/provost/planning/assessment/iapa/resources/pdfs/Handbook%20for%20Institutional%20Effectiveness.pdf> (13.04.2014)
210. Tierney, M. L. (1980). An estimate of departmental cost functions, *Higher Education*, 9(4): 453-468.
211. Tintor, J. (2009). Poslovna analiza, Masmedia, Zagreb
212. Toffler, A. (1990). Power Shift: Knowledge, Wealth and Violence at the edge of the 21st century. Bantam Books, New York
213. Tóth, R. 2009, 'Using DEA to evaluate efficiency of higher education', *Applied Studies in Agribusiness and Commerce*, 3(2-3): 79-82.
214. Tsai, P. F. i Mar Molinero, C. (2002). A variable returns to scale data envelopment analysis model for the joint determination of efficiencies with an example of the UK health service, *European Journal of Operational Research*, 141(1): 21–38.

215. Tse Kuah, C; Yew Wong, K. (2011). Efficiency assessment of universities through data envelopment analysis, *Procedia Computer Science* 3, 499–506.
216. Tzeremes, N., Halkos, G. (2010). A DEA approach for measuring university departments' efficiency, MPRA Paper 24029
217. UNESCO (1996). *Learning: The Treasure Within*, (Report of the International Commission od Education to UNESCO for Twenty First Century, Paris: UNESCO (Chair: Jaques Delors)
218. UNESCO (n.d.). Government expenditure on tertiary education as % of GDP (%), dostupno na: <http://data.uis.unesco.org/?queryid=181#> (14.07.2015),
219. Valadkhani, A., Worthington, A. (2005). *Ranking and Clustering Australian University Research Performance, 1998-2002*, School of Economics, University of Wollongong, NSW, Australia, Economics Working Papers No. 05-19
220. Vašiček, D. (2009). Računovodstvo i financijsko izvještavanje u funkciji upravljanja u javnom sektoru, *Hrvatska javna uprava*, 9(2): 393-420.
221. Vašiček, V. i Dražić Lutilsky, I. (2011). Upravljačko računovodstvo javnog sektora, Upravljačko računovodstvo i računovodstvo troškova u javnom sektoru – izabrane teme, Vašiček, V. (ur), *Računovodstvo i financije*, Zagreb (dio knjige – 1. poglavlje)
222. Vašiček, D., Dražić Lutilsky, I., Hladika, M. i Dragija, M. (2011). Trendovi u razvoju državnog računovodstva, Upravljačko računovodstvo i računovodstvo troškova u javnom sektoru – izabrane teme, Vašiček, V., Dragija, M. (ur), *Hrvatska zajednica računovođa i financijskih djelatnika*, Zagreb (dio knjige – 2. poglavlje)
223. Vašiček, V. (2015): Proračun i proračunski procesi, Zakonski okvir i obilježja djelatnosti, Planiranje proračuna, Izvršavanje proračuna, Riznica, dostupno na: <http://web.efzg.hr/dok/RAC//vvasicek/rno/prora%C4%8Dun%20i%20prora%C4%8Dunski%20proces%202015%20I%20DIO.pdf> (15.07.2015)
224. Vašiček, V., Budimir, V., Letinić, S. (2007). Pokazatelji uspješnosti u visokom obrazovanju, *Privredna kretanja i ekonomska politika*, 17(110): 51-80.
225. Vehovec, M. (2009): Neizravno javno financiranje visokog obrazovanja. *Revija za socijalnu politiku*, 16(2): 206-207.

226. Veinović, M. (2010) Uticaj bolonjskog procesa na obrazovanje informatičkih kadrova, Sinergija – V naučni skup
227. Verry, D. W, Layard, R. (1975). Costs functions for teaching and research, *The Economic Journal*, 85(337): 55-74.
228. Vidović, J. (2012). Računovodstvo proračuna i proračunskih korisnika, dostupno na: moodle.oss.unist.hr/mod/resource/view.php?id=14745 (13.09.2013)
229. Vlada Republike Hrvatske (n.d.). Polazne osnove Hrvatskoga kvalifikacijskog okvira, dostupno na: www.vlada.hr/hr/content/download/22392/.../file/243%20-%2012.pdf (5.02.2013)
230. Vlahinić – Dizdarević, N., Šegota, A. (2012). Total – factor energy efficiency in the EU countries, *Zbornik radova Ekonomskog fakulteta u Rijeci – časopis za ekonomsku teoriju i praksu*, 30(2): 247-265.
231. Wang, E.C. i Huang, W. (2007). Relative efficiency of R&D activities: A cross-country study accounting for environmental factors in the DEA approach, *Research Policy* 36(2): 260–273.
232. Webster, R., Kennedy, R., Johnson, L. (1998). Comparing Techniques for Measuring the Efficiency and Productivity of Australian Private Hospitals, Working Papers in Econometrics and Applied Statistics, Australian Bureau of Statistics, No. 98/3
233. Witten, I.H., Frank, E. (2005). Data mining, Practical Machine Learning Tools and Techniques, Morgan Kaufmann
234. Wolszczak - Derlacz, J & Parteka, A. (2011). Efficiency of European public higher education institutions: a two stage multicountry approach, *Scientometrics*, 89(3): 887-917
235. Woodhall, M. (2004). Cost-benefit analysis in educational planning, UNESCO: International Institute for Educational Planning, dostupno na: <http://unesdoc.unesco.org/images/0013/001390/139042e.pdf> (9.05.2015)
236. Yang, Z. (2009) Bank Branch Operating Efficiency: A DEA Approach, Proceedings of the International MultiConference of Engineers and Computer Scientists 2009 Vol II, IMECS 2009, March 18 - 20, 2009, Hong Kong

237. Zakon o osiguravanju kvalitete u znanosti i visokom obrazovanju (NN 45/09).
238. Zakon o proračunu (NN 87/08, 136/12, 15/15)
239. Zakon o visokim učilištima (NN 96/93, 54/96)
240. Zakon o ustanovama (NN 76/93., 29/97., 47/99., 35/08.)
241. Zakon o znanstvenoj djelatnosti i visokom obrazovanju (NN 123/03, 198/03, 105/04, 174/04, 02/07, 46/07, 45/09, 63/11, 94/13, 139/13, 101/14, 60/15)
242. Zaldívar-Colado, A., Estrada-Lizárraga, R. Nava-Pérez, L. Mendoza-Zatarain, R., Aguilar-González, C. (2012). Application of cluster analysis for identification of variables associated with academic success of higher education students, ICERI2012 Proceedings, p. 2170-2176, 5th International Conference of Education, Research and Innovation, 19-21 November, 2012, Madrid, Spain

POPIS TABLICA

Tablica 1: Kriteriji, indikatori i ponderi prema „Shangai ranking“	12
Tablica 2: Metodologija rangiranja visokoobrazovnih institucija prema „Webometrics“.....	13
Tablica 3: Ukupni javni izdaci na obrazovanje i visoko obrazovanje kao udio u BDP-u (2009 – 2011).....	32
Tablica 4: Udio javnog i privatnog financiranja visokog obrazovanja u promatranim državama EU od 2009 – 2011	33
Tablica 5: Godišnja izdvajanja na visoko obrazovanje po studentu, bez sredstava za istraživanje i razvoj 2004. i 2011.....	34
Tablica 6: Proračunska ulaganja Ministarstva znanosti, obrazovanja i sporta Republike Hrvatske u visoko obrazovanje, znanost i tehnologiju u milijunima kuna	36
Tablica 7: Udjel visokog obrazovanja i IiR-a u BDP-u Hrvatskoj od 2007. - 2011. godine ...	37
Tablica 8: Udio prihoda i rashoda po vrsti u ukupnim prihodima i rashodima javnih sveučilišta u Hrvatskoj	38
Tablica 9: Promjene u prihodima i rashodima Sveučilišta u Hrvatskoj u 2012. u odnosu na 2011. godinu.....	39
Tablica 10: Raspodjela vlastitih prihoda visokih učilišta u Republici Hrvatskoj	41
Tablica 11: Izdaci za istraživanje i razvoj od 2002. do 2013. kao udio u BDP – u izabranim zemljama Europe	43
Tablica 12: Struktura računskog plana proračunskog računovodstva u Republici Hrvatskoj .	50
Tablica 13: Računski plan društveno odgovornog računovodstva.....	66
Tablica 14: Upisani na visoko ekonomsko obrazovanje od 2011./12. – 2013./14.....	81
Tablica 15: Prikaz strukture prihoda javnih ekonomskih fakulteta i Fakulteta za menadžment u turizmu i ugostiteljstvu u Opatiji od 2009. - 2012.	83
Tablica 16: Prikaz strukture rashoda javnih ekonomskih fakulteta i Fakulteta za menadžment u turizmu i ugostiteljstvu u Opatiji od 2009. - 2012.	84
Tablica 17: Matrica efikasnosti i efektivnosti	106
Tablica 18: Pregled mjera udaljenosti i sličnosti	127
Tablica 19: Pregled inputa i outputa referentne literature	143
Tablica 20: Deskriptivna statistika inputa i outputa za model nastavna djelatnost.....	151
Tablica 21: Koeficijenti korelacije inputa i outputa za model nastavna djelatnost.....	151
Tablica 22: Deskriptivna statistika inputa i outputa za model znanstveno-stručna djelatnost	152
Tablica 23: Koeficijenti korelacije inputa i outputa za model znanstveno-stručna djelatnost	152
Tablica 24: Deskriptivna statistika inputa i outputa za model međunarodna djelatnost.....	152

Tablica 25: Koeficijenti korelacije inputa i outputa za model međunarodna djelatnost.....	152
Tablica 26: Deskriptivna statistika inputa i outputa za model cjelokupna djelatnost	153
Tablica 27: Koeficijenti korelacije inputa i outputa za model cjelokupna djelatnost	153
Tablica 28: Rezultati relativne efikasnosti primjenom CCR i BCC modela s output orijentacijom za sve modele	154
Tablica 29: Rezultati relativne efikasnosti visokoobrazovnih institucija ekonomskog usmjerenja po različitim modelima	155
Tablica 30: Učestalost pojavljivanja relativno efikasnih visokoobrazovnih institucija u referentnom skupu i članovi referentnog skupa po svakom modelu.....	157
Tablica 31: Podaci o prosječnim poboljšanjima (projekcijama) za relativno neefikasne visokoobrazovne institucije.....	159
Tablica 32: Podaci o potencijalnim poboljšanjima za DO25 u modelu Nastavna djelatnost.	159
Tablica 33: Podaci o potencijalnim poboljšanjima za DO12 u modelima Nastavna djelatnost, Znanstveno-stručna djelatnost i Međunarodna djelatnost.....	159
Tablica 34: DO raspoređeni u klasterne temeljem rezultata relativne efikasnosti tri različita područja vrednovanja	162
Tablica 35: Karakteristike klastera i rezultati Mann-Whitney testa.....	163
Tablica 36: Snaga povezanosti između zavisne i nezavisnih varijabli Cramerov V.....	165
Tablica 37: Rezultati univarijantne binarne logističke regresije po svakoj varijabli	166
Tablica 38: Deskriptivna statistika inputa i outputa za model znanstveno-stručna djelatnost	168
Tablica 39: Koeficijenti korelacije inputa i outputa za model znanstveno-stručna djelatnost	168
Tablica 40: Rezultati relativne efikasnosti primjenom CCR i BCC modela s output orijentacijom za model ZD_1	169
Tablica 41: Učestalost pojavljivanja relativno efikasnih visokoobrazovnih institucija u referentnom skupu i članovi referentnog skupa za model ZD_1	169
Tablica 42: Podaci o prosječnim poboljšanjima (projekcijama) za relativno neefikasne visokoobrazovne institucije.....	170
Tablica 43: DO raspoređeni u klasterne temeljem rezultata relativne efikasnosti tri različita područja vrednovanja (alternativni model)	171
Tablica 44: Karakteristike klastera i rezultati Mann-Whitney testa (alternativni model).....	172
Tablica 45: Snaga povezanosti između zavisne i nezavisnih varijabli Cramerov V (alternativni model).....	174
Tablica 46: Rezultati univarijantne binarne logističke regresije po svakoj varijabli (alternativni model).....	175

POPIS GRAFIKONA

Grafikon 1: Izdaci za istraživanje i razvoj od 2002. do 2013. kao udio u BDP – usporedni prikaz RH i prosjeka EU (28)	44
Grafikon 2: Usporedni prikaz ulaganja u IiR kao % BDP-a Hrvatske i izabranih zemalja Europe u 2013. godini	45
Grafikon 3: Ulaganja U IiR prema izvoru sredstava za Hrvatsku i izabrane zemlje Europe u 2013. godini	46
Grafikon 4: Objavljeni istraživački radovi u Hrvatskoj prema mjestu objavljivanja na razini svih sektora ukupno, područje društvenih znanosti na razini svih sektora ukupno, polje ekonomija na razini svih sektora ukupno u 2013. godini	47
Grafikon 5: Objavljeni istraživački radovi u Hrvatskoj prema mjestu objavljivanja u visokom obrazovanju, područje društvenih znanosti, polje ekonomija u 2013. godini.....	48
Grafikon 6: Udio zaposlenih u društvenim znanostima i visokom obrazovanju prema vrsti zaposlenosti u Republici Hrvatskoj u 2013. godini	49
Grafikon 7: Međuodnos efikasnosti i efektivnosti na primjeru visokog obrazovanja	107
Grafikon 8: CCR inputu i outputu usmjeren model	119
Grafikon 9: Projekcije na granicu efikasnosti ovisno o orijentaciji	122
Grafikon 10: Efikasnost prema CRS i VRS formulacijama.....	123
Grafikon 11: Logistička funkcija za različite vrijednosti parametara k i a	132
Grafikon 12: Dendrogram klaster analize visokoobrazovnih institucija ekonomskog usmjerenja temeljem rezultata relativne efikasnosti.....	161
Grafikon 13: Box plot za ND, ZD i MD po pojedinom klasteru	163
Grafikon 14: Dendrogram klaster analize visokoobrazovnih institucija ekonomskog usmjerenja temeljem rezultata relativne efikasnosti (alternativni model).....	171
Grafikon 15: Box plot za ND, ZD_1 i MD po pojedinom klasteru (alternativni model).....	173

POPIS SHEMA

Shema 1: Struktura javnog sektora Republike Hrvatske.....	22
Shema 2: Institucionalni prikaz hrvatskog javnog sektora - subjekti opće države i jedinice lokalne i regionalne samouprave.....	23
Shema 3: Knjigovodstveni sustav društveno odgovornog računovodstva.....	64
Shema 4: Ciklički prikaz efekata povećanja kvalitete obrazovanja.....	71
Shema 5: Visoko obrazovanje u sustavu razvoja gospodarstva.....	72
Shema 6: Prikaz sustava visokog obrazovanja u Hrvatskoj definiranih Bolonjskim procesom.....	77
Shema 7: Ustroj sustava visokog obrazovanja i znanosti u Republici Hrvatskoj.....	78
Shema 8: Uloga Europskog kvalifikacijskog okvira kao instrumenta uspostave kvalifikacija između različitih zemalja: primjer Republike Hrvatske (Hrvatski kvalifikacijski okvir).....	89
Shema 9: Hrvatski kvalifikacijski okvir.....	90
Shema 10: Nacionalni sustav osiguranja kvalitete visokog obrazovanja u sklopu međunarodnog obrazovnog tržišta.....	96
Shema 11: Sustav osiguranja kvalitete u Republici Hrvatskoj.....	97
Shema 12: Organizacijska struktura Agencije za znanost i visoko obrazovanje.....	99
Shema 13: Rastavljanje efikasnosti na temeljne vrste.....	102
Shema 14: Povezanost efikasnosti i efektivnosti.....	105
Shema 15: Proces vrednovanja efikasnosti korištenjem analize omeđivanja podataka.....	110
Shema 16: Postupak klasterizacije kod aglomerativnih i dijelećih hijerarhijskih.....	128
Shema 17: Prikaz empirijskog modela vrednovanja efikasnosti visokoobrazovanih institucija ekonomskog obrazovanja.....	140
Shema 18: Definiranje ciljeva razvoja visokog obrazovanja.....	179
Shema 19: Proces unutarnjeg vrednovanja ishoda u funkciji ostvarivanja efektivnosti visokoobrazovanih institucija.....	181

KAZALO KRATICA

- AE – Alokativna efikasnost (eng. *allocative efficiency*)
- AOMP – Analiza omeđivanja podataka (eng. *Data envelopment analysis – DEA*)
- AZVO, Agencija – Agencija za znanost i visoko obrazovanje
- BDP – Bruto društveni proizvod
- BCC - Banker, Charnes i Cooper - ov model
- BCC₀ - Linearni program za rješavanje inputu usmjerenog BCC modela
- BCC – O₀ – Linearni program za rješavanje outputu usmjerenog BCC modela
- BSC – bilanca postignuća (eng. *Balanced scorecard*)
- CCR - Charnes, Cooper i Rhodes - ov model
- CRS – Konstantni prinosti (eng. *Constant returns to scale*)
- DOR – Društveno odgovorno računovodstvo
- ČTE – Čista tehnička efikasnost
- DO – Donosioc odluke (eng. *Decision making unit – DMU*)
- DO₀ – Donosioc odluke čija se efikasnost procjenjuje
- DZS – Državni zavod za statistiku
- E4 skupina - ENQA, EUA, ESU, EURASHE
- EF – Ekonomski fakultet
- EFOS – Ekonomski fakultet u Osijeku
- EFRI – Ekonomski fakultet u Rijeci
- EFST – Ekonomski fakultet u Splitu
- EFPU – Fakultet ekonomije i turizma "Dr. Mijo Mirković" iz Pule
- EFZG – Ekonomski fakultet u Zagrebu
- ENQA- Europsko udruge za osiguranje kvalitete u visokom obrazovanju (eng. *European Association for Quality Assurance in Higher Education*)
- EO – Efikasnost obujma
- ESA – Europski sustav računa (eng. *European System of Accounts*)
- ESG - Standardi i smjernice za osiguravanje kvalitete u Europskom prostoru visokog obrazovanja (eng. *Standards and Guidelines for Quality Assurance in the European Higher Education Area*)
- ESU – Europski studentski zbor (eng. *European Students Union*)

- EU – Europska unija
- EUA - Europska udruga sveučilišta (eng. *European Association of Universities*)
- EURASHE – Europska udruga visokih učilišta (eng. *European Association of Institution in Higher Education*)
- FP – Frakcijsko (razlomljeno) programiranje
- GFS – Statistika državnih financija (eng. *Government Finance Statistics*)
- HKO – Hrvatski kvalifikacijski okvir
- ICT – Informacijska i komunikacijska tehnologija (eng. *Information and Communications Technology*)
- IiR – Istraživanje i razvoj
- IREG - Međunarodna skupina eksperata za rangiranje (eng. *International Ranking Expert Group*)
- INQAAHE – Međunarodna mreža agencija za osiguravanje kvalitete u visokom obrazovanju (eng. *International Network for Quality Assurance Agencies in Higher Education*)
- LP – Linearno programiranje
- MMF – Međunarodni monetarni fond
- MZOS - Ministarstvo znanosti, obrazovanja i sporta Republike Hrvatske
- NKO – Nacionalni kvalifikacijski okvir
- NVVO – Nacionalno vijeće za visoko obrazovanje
- OLS – metoda najmanjih kvadrata (eng. *ordinary least-squares*)
- QA – osiguranje kvalitete (eng. *quality assurance*)
- QAA – agencija za osiguranje kvalitete (eng. *quality assurance agency*)
- PE – profitna efikasnost (eng. *profit efficiency*)
- RE – prihodovna efikasnost (eng. *revenue efficiency*)
- RH - Republika Hrvatska
- SAD – Sjedinjene američke države
- SFA - stohastička analiza granica (eng. *stochastic frontier analysis*)
- SNA – Sustav nacionalnih računa (eng. *System of National Accounts*)
- TE – Tehnička efikasnost (eng. *technical efficiency*)
- UJF – Udio javnih financija
- UNIDU – Sveučilište u Dubrovniku

- UNIZG – Sveučilište u Zagrebu
- UPF – Udio privatnih financija
- VOI – Visokoobrazovne institucije
- VRS – Varijabilni prinosi (eng. *Variable returns to scale*)
- ZOP – Zakon o proračunu Republike Hrvatske
- ZZDVO - Zakon o znanstvenoj djelatnosti i visokom obrazovanju

PRILOG 1:

Potencijalna poboljšanja za modele Nastavni rad, Znanstveni rad, Međunarodna suradnja i Ukupan model

	Nastavna djelatnost		Znanstvena djelatnost				Međunarodna djelatnost				Cjelokupna djelatnost					
	DIPL		SRAD		ZRAD		Mob S		Mob ZO		Mobilnost		DIPL		ZSRAD	
DO	Data	Proj.	Data	Proj.	Data	Proj.	Data	Proj.	Data	Proj.	Data	Proj.	Data	Proj.	Data	Proj.
DO1	966	1055,24	20	47,01	102	225,67	12	49,403	14	55,3	26	26	966	966	122	122
DO2	1161	1161	32	68,42	111	237,32	68	344,06	11	55,7	79	79	1161	1161	143	143
DO3	523	1210,13	21	59,08	155	283,42	69	207,76	17	51,2	86	111,03	523	675,21	176	227,22
DO4	2428	2428,01	87	151,4	472	723,61	118	144,82	61	74,9	179	179	2428	2428	559	559
DO5	1149	1213,49	12	37,67	58	178,58	33	174,29	12	63,4	45	45	1149	1149	70	70,004
DO6	139	614,56	2	2	36	36	9	48,776	5	27,1	14	79,977	139	369	38	100,88
DO7	39	508,80	3	22,87	39	109,63	3	102,6	7	68,5	10	112,34	39	209,7	42	135,23
DO8	98	444,72	5	20,9	15	62,688	0	0,001	0	0	0	25,164	98	218,32	20	44,555
DO9	445	1295,95	2	9,145	7	32,007	3	36,4	3	36,4	6	37,067	445	894,04	9	66,504
DO10	228	685,07	36	36	17	17	133	339,27	22	56,1	155	180,96	228	423,14	53	140,92
DO11	170	808,46	0	0,002	0	0,0015	8	29,743	8	29,7	16	50,919	170	541,02	0	61,126
DO12	19	26,89	14	22,11	12	18,951	15	22,65	20	30,2	35	35	19	19	26	26
DO13	91	191,88	1	3,333	14	31	2	52,196	0	7,03	5	9,5379	91	173,59	15	44,276
DO14	25	93,14	0	9E-04	0	0,0009	7	14,991	6	12,8	13	20,904	25	55,004	0	0
DO15	17	17	1	9,885	2	19,77	5	5	20	20	25	25	17	17	3	3
DO16	90	90	14	14	12	12	6	15,711	7	18,3	13	13	90	90,001	26	26
DO17	47	47	6	6	21	21	0	3,3084	3	14,7	3	3,0002	47	47	27	27
DO18	64	94,14	0	4,855	22	25,286	4	10,59	3	7,94	7	9,6359	64	88,1	0	30,284
DO19	200	200	0	9,764	4	46,464	2	78,291	0	8,54	2	2,0001	200	200	0	4,0002
DO20	95	95,39	17	17	17	17	0	8E-08	4	4	4	4	95	95	34	34
DO21	388	737,95	2	10,43	6	31,289	13	38,003	19	52,4	32	55,427	388	672,05	8	109,44
DO22	655	1176,32	4	20,52	5	25,65	5	5,5106	13	14,3	18	18	655	655	9	9

DO23	488	508,80	37	37	107	107	97	200,95	26	53,9	123	123	488	488	144	144
DO24	423	1176,00	34	34	161	161	63	133	37	76	100	205,42	423	559,88	195	258,1
DO25	1339	1685,80	186	186	276	276	548	548	36	36	584	584	1339	1339	462	462
DO26	100	549,90	7	23,13	40	110,62	42	122,78	12	35,1	54	98,617	100	182,62	47	95,442
DO27	202	1072,67	50	50	240	240	133	133	76	76	209	209	202	202	290	290
DO28	131	379,77	11	26,52	31	74,742	0	3,0879	4	28,6	4	33,156	131	250,98	42	80,468
DO29	121	121	10	10	25	25	20	30,33	28	42,5	48	48	121	121	35	35
DO30	28	185,40	7	15,86	27	61,194	4	25,749	4	25,7	8	26,344	28	79,279	34	51,093
DO31	802	1385,92	20	56,85	80	227,39	0	7E-05	43	43	43	54,802	802	1007,3	100	125,6

Izvor: Izrada autorice

PRILOG 2:

Potencijalna poboljšanja za alternativni model Znanstveni rad_1

DO	ZRAD	
	Data	Projection
DO1	102	224,912
DO2	111	242,715
DO3	155	258,996
DO4	472	472,001
DO5	58	171,004
DO6	36	36
DO7	39	107,855
DO8	15	65,7631
DO9	7	36
DO10	17	36
DO11	0	0,00061
DO12	12	29,5714
DO13	14	31
DO14	0	0,00043
DO15	2	21,7143
DO16	12	12,0002
DO17	21	21
DO18	22	25,2857
DO19	4	42,47
DO20	17	22,4286
DO21	6	36
DO22	5	36
DO23	107	107,983
DO24	161	161
DO25	276	313,359
DO26	40	109,008
DO27	240	240
DO28	31	81,2918
DO29	25	25
DO30	27	60,6739
DO31	80	181,735

Izvor: Izrada autorice

ŽIVOTOPIS

Andrea Arbula Blecich rođena je 5. ožujka 1985. godine u Rijeci. Osnovno i srednje školovanje završila je u Rijeci. Sveučilišni studij na Ekonomskom fakultetu u Rijeci završila je 2008. godine.

Neposredno nakon diplomiranja, 2009. godine zaposlena je kao znanstveni novak na Ekonomskom fakultetu u Rijeci na kojem je iste godine i upisala Poslijediplomski doktorski studij ekonomije i poslovne ekonomije, smjer: poslovna ekonomija. Kao suradnik bila je angažirana na znanstveno-istraživačkim projektima: Koncepti i metode troškovnog računovodstva u javnom sektoru Republike Hrvatske financiranom od strane MZOŠ-s (završio 2013.), Koncepti i metode troškovnog i upravljačkog računovodstva u javnom sektoru republike Hrvatske financiranom od strane Sveučilišta u Rijeci te na projektu Business and Personal Insolvency - the Ways to Overcome Excessive Indebtednes financiranom od strane HRZZ-a. Voditeljica projekata je prof. dr. sc. Mira Dimitrić.

Pored angažmana na znanstvenim projektima, kao znanstveni novak, uključena je u nastavni proces preddiplomskog i diplomskog studija na Ekonomskom fakultetu u Rijeci na kojima održava vježbe i seminare iz kolegija: Računovodstvo troškova, Računovodstvo financijskih institucija i Restrukturiranje i sanacija poduzeća. Uz nastavne obveze članica je Odbora za osiguranje i unaprjeđenje kvalitete na Ekonomskom fakultetu u Rijeci.

Znanstveni radovi:

1. Tomas Žiković, I., Žiković, S., Arbula Blecich, A. (2016). The drivers behind household and corporate non-performing loans ratio: Case of Croatia, Privredna kretanja i ekonomska politika (rad prihvaćen za objavu)
2. Cerović, Lj., Arbula Blecich, A., Štambuk, A. (2014). Relevant Areas and Indicators of Quality in Higher Education Institutions: Evaluating the System of Higher Education in Economics, Management: Journal of Contemporary Management Issues, 19, 2, p. 89-116;
3. Dukić, N., Arbula Blecich, A., Cerović, Lj. (2013). Economic Implications of Insufficient Health Literacy, Ekonomska istraživanja, 26, Special Issue, p. 117-132
4. Arbula Blecich, A. (2012). Using Data Envelopment Analysis To Evaluate The Efficiency Of Higher Education Expenditure In Europe, Journal of International Scientific Publications: Economy & Business, p. 59-69.
5. Arbula, A. (2012). Pregled pristupa vrednovanja troškovne učinkovitosti visokog obrazovanja, Financije i menadžment u globalnoj ekonomiji, p. 281-295.
6. Cerović, Lj., Arbula, A. (2012). Razumne granice vrednovanja sustava visokog ekonomskog obrazovanja, Ekonomsko obrazovanje u Republici Hrvatskoj - jučer, danas, sutra / Čavrak, Vladimir ; Gelo, Tomislav (ur.). - Zagreb : Ekonomski fakultet Sveučilišta u Zagrebu, p. 38-40.
7. Arbula, A. (2011). Financiranje visokog obrazovanja u odabranim članicama EU-a i Hrvatskoj s osvrtom na javne ekonomske fakultete u Hrvatskoj, Znanstvena monografija interkatedarskog skupa katedri za financije: Hrvatska financijska tržišta i institucije u procesu uključivanja u EU
8. Blecich, P., Franković, B., Arbula, A. (2011). Financial viability of energy efficiency measures for single-family houses in three urban areas of Europe, ISES Solar World Congress 2011 Book of Proceedings

IZJAVA

Izjavljujem i svojim potpisom potvrđujem da je doktorska disertacija isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, što pokazuje korištenje bilješke i bibliografija. Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem, također da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj znanstvenoj ili obrazovnoj ustanovi.

Student

U Rijeci, 15. prosinca 2015.