Ocjena učinkovitosti upravljanja hrvatskim gradovima metodom omeđivanja podataka (AOMP)

Bogović, Tomislav

Doctoral thesis / Disertacija

2014

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics Varaždin / Sveučilište u Zagrebu, Fakultet organizacije i informatike Varaždin**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:211:386247

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

KORICE



Sveučilište u Zagrebu

FAKULTET ORGANIZACIJE I INFORMATIKE

Tomislav Bogović

OCJENA UČINKOVITOSTI UPRAVLJANJA HRVATSKIM GRADOVIMA METODOM OMEĐIVANJA PODATAKA (AOMP)

DOKTORSKI RAD

Varaždin, 2014.

PODACI O DOKTORSKOM RADU

I. AUTOR

Ime i prezime	Tomislav Bogović
Datum i mjesto rođenja	13. studenoga 1966., Varaždin
Naziv fakulteta i datum diplomiranja na VII/I stupnju	Sveučilište u Zagrebu, Agronomski fakultet, 29. kolovoza 1991.
Naziv fakulteta i datum diplomiranja na VII/II stupnju	Sveučilište u Zagrebu, Fakultet organizacije i informatike, 19. svibnja 2007.
Sadašnje zaposlenje	Grad Varaždin, viši savjetnik za poduzetništvo

II. DOKTORSKI RAD

Naslov	Ocjena učinkovitosti upravljanja hrvatskim gradovima metodom omeđivanja podataka (AOMP)
Broj stranica, slika, tablica, priloga, bibliografskih podataka	Stranica 127, slika 32, tablica 19, bibliografskih podataka 226
Znanstveno područje i polje iz kojega je postignut doktorat znanosti	Područje društvenih znanosti, polje informacijskih znanosti
Mentori ili voditelji rada	Prof. dr. sc. Tihomir Hunjak
Fakultet na kojem je obranjen doktorski rad	Fakultet organizacije i informatike, Varaždin
Oznaka i redni broj rada	

III. OCJENA I OBRANA

Datum sjednice Fakultetskoga vijeća na kojoj je prihvaćena tema	20. ožujka 2013.
Datum predaje rada	10. srpnja 2014.
Datum sjednice Fakultetskoga vijeća na kojoj je prihvaćena pozitivna ocjena rada	26. rujna 2014.
Sastav povjerenstva koje je rad ocijenilo	Izv. prof. dr. sc. Diana Šimić Prof. dr. sc. Tihomir Hunjak Prof. dr. sc. Zdravko Petak
Datum obrane doktorskoga rada	19. prosinca 2014.
Sastav povjerenstva pred kojim je rad obranjen	Izv. prof. dr. sc. Diana Šimić Prof. dr. sc. Tihomir Hunjak Prof. dr. sc. Zdravko Petak
Datum promocije	



Sveučilište u Zagrebu
Fakultet organizacije i informatike

TOMISLAV BOGOVIĆ

OCJENA UČINKOVITOSTI UPRAVLJANJA HRVATSKIM GRADOVIMA METODOM OMEĐIVANJA PODATAKA (AOMP)

DOKTORSKI RAD

Mentor: prof. dr. sc. Tihomir Hunjak

Varaždin, 2014.



University of Zagreb

Faculty of Organization And Informatics

Tomislav Bogović

ASSESSMENT OF THE EFFICIENCY OF CROATIAN CITIES USING DATA ENVELOPMENT ANALYSIS (DEA)

DOCTORAL THESIS

Varaždin, 2014.

"Mi smo ušli u urbano tisućljeće u kojem su gradovi motori rasta i inkubatori civilizacije. Oni su raskrižje ideja, kvasac intelektualnoga razvoja i inovacija, no gradovi također mogu biti i mjesta izrabljivanja, bolesti, nasilnih zločina, nezaposlenosti, krajnje bijede i siromaštva.
Mi moramo učiniti više kako bi naši gradovi bili sigurna i podnošljiva mjesta za sve. "

Kofi Annan (2000.)

ZAHVALE

Društveno odgovorno i učinkovito upravljanje javnim resursima u cilju postizanja višega standarda i bolje kvalitete života glavna je misao vodilja ovoga rada koji je nastao kao odgovor na pitanje koja je uloga političkoga menadžmenta u procesu upravljanja lokalnom samoupravom i kako na objektivan način ocijeniti njihovu kvalitetu.

Na prijedlog prof. dr. sc. Tihomira Hunjaka, za analizu učinkovitosti upravljanja gradovima u Republici Hrvatskoj odabrana je metoda analize omeđivanja podataka koja je u svijetu prihvaćena kao jedan od kvalitetnih menadžerskih alata koji omogućuje utvrđivanje relativne učinkovitosti više usporedivih jedinica na osnovi odabranih inputa i outputa.

Ovaj rad kroz četiri poglavlja analizira ulogu gradova u općem društvenom razvoju stavljajući naglasak na ulogu političkoga menadžmenta koji, kreirajući razvojne politike, ima glavnu ulogu u stvaranju preduvjeta za razvoj zajednice izražen stupnjem gospodarskoga razvoja i općega prosperiteta zajednice.

U istraživanju učinkovitosti upravljanja velikim gradovima u Republici Hrvatskoj metodom analize omeđivanja podataka i interpretaciji dobivenih rezultata prikazane su mogućnosti te metode kao korisnoga menadžerskog alata koji omogućuje i vanjsko vrjednovanje rada lokalnih vlasti svim javnim dionicima.

U cilju unaprjeđenja metode i njezine praktične primjene prikazane su mogućnosti njezine implementacije u sustav poslovne inteligencije i izrađen je koncept web-servisa. U posljednjem su poglavlju navedeni zaključci koji su proizašli iz dobivenih rezultata istraživanja i prikazana je kratka sinteza rada te su naznačeni daljnji mogući smjerovi istraživanja.

Na kraju bih se zahvalio svima koji su mi na bilo koji način pomogli u izradbi ovoga rada.

Prije svega zahvaljujem Fakultetskomu vijeću Fakulteta organizacije i informatike Varaždin, što mi je prihvatilo temu disertacije.

Osobitu zahvalnost iskazujem mentoru prof. dr. sc. Tihomiru Hunjaku kojemu se zahvaljujem na sugestijama pri izboru teme, korisnim napomenama i vođenju u izradbi doktorske disertacije.

Na podršci i razumijevanju posebno se zahvaljujem svojoj obitelji, prije svega supruzi Mari i djeci Mariji Gabrijeli, Magdaleni, Heleni i Janku.

SAŽETAK

Gradovi nemaju jednake potencijale za razvoj i lokalne vlasti na različite načine koriste resurse u upravljanju razvojem što ih čini više ili manje uspješnima. U okviru ovog doktorskoga rada provedeno je znanstveno istraživanje efikasnosti korištenja javnih resursa u ostvarivanju određenih učinaka na ekonomske performanse društvenog razvoja, kao mjere učinkovitosti upravljanja gradovima u Republici Hrvatskoj. Korištena je metoda analize omeđivanja podataka (AOMP) koja omogućuje utvrđivanje relativne efikasnosti više usporedivih entiteta na osnovi odabranih ulaza (eng. *input*) i izlaza (eng. *output*). Istraživanje je provedeno na populaciji petnaest velikih gradova u Republici Hrvatskoj tijekom jednog mandata koji je trajao od 2005. do 2008. godine, a u analizu je bilo uključeno ukupno sedam karakterističnih pokazatelja. Relativna učinkovitost upravljanja je određena na temelju izračuna CCR i BCC modela usmjerenih izlazima.

Rezultati su ukazali kojim se gradovima učinkovito upravlja te koje resurse vlasti u neučinkovitim gradovima trebaju efikasnije koristiti i koje rezultate moraju postizati da bi postali učinkoviti. Učinkoviti gradovi su istaknuti kao primjeri dobre prakse upravljanja, a prema njihovim frekvencijama u referentnim skupovima neučinkovitih gradova određeni su referentni partneri.

Usporedbom relativne učinkovitosti upravljanja gradovima u kombinaciji nediskrecijskih (eng. *non controllable*) i diskrecijskih (eng. *controllable*) ulaza sa pokazateljima ekonomske razvijenosti i gospodarskog potencijala gradova testirana je osnovna teza o dominaciji kompetitivnosti donositelja odluka nad materijalnim resursima, a za procjenu utjecaja (dis)kontinuiteta vlasti na relativnu učinkovitost korištena je AOMP analiza prozora (eng. *Window*). U radu su ispitane mogućnosti implementacije AOMP-a, kao korisnog analitičkog alata, u sustav poslovne inteligencije i kao platforme za kreiranje javnog Web servisa koji bi koristio političkom menadžmentu kao snažna podrška donošenju odluka i upravljanju, ali i svim javnim dionicima koji su zainteresirani za ocjenu učinkovitosti upravljanja javnim resursima.

Provedeno znanstveno istraživanje pokazuje da je moguće standardizirati metodologiju ocjenjivanja učinkovitosti javnog sektora u Republici Hrvatskoj koristeći AOMP kao koristan i primjenjiv menadžerski alat za upravljanje javnim sektorom i ocjenu uspješnosti političkog menadžmenta.

Ključne riječi: učinkovitost, upravljanje gradovima, analiza omeđivanja podataka

ABSTRACT

Cities do not always have the same potential for development, so local authorities utilise resources in different ways with varying degrees of success when managing development. As a part of this thesis, scientific research was carried out on how efficiently public resources are used in effecting the economic aspects of social development, if used as management efficiency measures within Croatian cities. A Data Envelopment Analysis (DEA) was used, which allows the relative efficacy of several comparable entities to be determined on the basis of selected inputs and outputs. This study was conducted in fifteen major Croatian cities during a single electoral cycle between 2005 and 2008, and the analysis included seven characteristic indicators. The relative effectiveness of this management was determined on the basis of CCR and BCC targeted output models.

The results indicate which cities are efficiently managed and show which resources the authorities in inefficient cities should efficiently use in order to become more effective. The efficiently managed cities are highlighted as examples of good management practice and, according to their frequency in reference groups within inefficient cities, benchmarking partners are defined.

By comparing the relative effectiveness of a local administration combined with non controllable and controllable inputs with indicators of the economic development and economic potential of the cities involved, a basic thesis was tested about the domination of decision makers' competitiveness over material resources. To assess the impact of government (dis)continuity around efficiency, the DEA Window analysis was assessed.

This paper investigates the possibilities of implementing DEA into a business intelligence system as a useful analytical tool and platform to create public web services that would serve political management as a strong support for decision making and control as well as all stakeholders interested in evaluating the effectiveness of public resource management.

This scientific research shows that it is possible to standardise the methodology used to analyse the efficiency of the Croatian public sector using DEA information, and this can be a useful and effective public sector management tool for evaluating the success of political management.

Keywords: efficiency, city management, data envelopment analysis

SADRŽAJ

SADRŽAJ ..... **I**

POPIS SLIKA ..... **III**

POPIS TABLICA ..... **IV**

KRATICE ..... **V**

1. UVOD **1**

1.1. PREDMET ISTRAŽIVANJA 2

1.2. SVRHA ISTRAŽIVANJA 4

1.3. CILJEVI ISTRAŽIVANJA I HIPOTEZE 5

1.4. DOPRINOS ISTRAŽIVANJA 6

2. UČINKOVITOST UPRAVLJANJA LOKALNOM SAMUPRAVOM **8**

2.1. ULOGA GRADOVA U GOSPODARSKOM RAZVOJU 8

2.2. LOKALNI EKONOMSKI RAZVOJ I RAZVOJNE POLITIKE 10

2.3. RAZVOJNI POTENCIJALI I KONKURENTNOST GRADOVA 11

2.4. UTJECAJ UPRAVLJANJA NA GOSPODARSKI RAZVOJ GRADOVA 12

2.5. OSNOVNA OBILJEŽJA UPRAVLJANJA GRADOVIMA U REPUBLICI HRVATSKOJ 13

2.6. VODSTVO I UČINKOVITOST UPRAVLJANJA GRADOVIMA 15

3. PRIKAZ METODA ZA MJERENJE UČINKOVITOSTI LOKALNE SAMOUPRAVE **17**

3.1. MODEL URAVNOTEŽENIH CILJEVA - BSC 18

3.1.1. FAZE IZRADBE BSC-A 24

3.1.2. MOGUĆNOSTI I OGRANIČENJA PRIMJENE BSC-A U LOKALNOJ SAMOUPRAVI 27

3.2. EUROPSKI MODEL POSLOVNE IZVRSNOSTI (EFQM) 28

3.2.1. MOGUĆNOSTI I OGRANIČENJA PRIMJENE MODELA EFQM-A U LOKALNOJ SAMOUPRAVI 36

3.3. ZAJEDNIČKI OKVIR ZA OCJENJIVANJE - CAF 37

3.3.1. SAMOOCJENJIVANJE CAF MODELOM U LOKALNOJ SAMOUPRAVI 41

3.4. ANALIZA OMEĐIVANJA PODATAKA - AOMP 44

3.4.1. MODELI AOMP-A 48

3.4.1.1. CHARNES COOPER RHODESOV MODEL (CCR) 49

3.4.1.2. Banker Charner Cooperov model (BCC) 52
3.4.2. Identifikacija performansi 58
3.4.3. Pregled dosadašnjih istraživanja 61
4. ISTRAŽIVANJE 65
4.1. Metodologija i plan istraživanja 65
4.2. Odabir modela AOMP-a 66
4.3. Odabir ulaza i izlaza za analizu učinkovitosti hrvatskih gradova 67
4.4. Empirijski podaci za analizu učinkovitosti gradova u RH 72
4.5. Statistička verifikacija podataka 77
4.6. Rezultati analize relativne učinkovitosti upravljanja hrvatskim gradovima 79
4.6.1. Relativna učinkovitost gradova 79
4.6.2. Izvori neučinkovitosti i projekcija na granicu učinkovitosti 85
4.6.3. Analiza prozora (eng. *window*) 93
4.7. Analiza učinkovitosti s nediskrecijskim ulazima 96
4.8. Odnos učinkovitosti upravljanja i ekonomske razvijenosti gradova 98
4.8.1. Odnos učinkovitosti upravljanja i indeksa razvijenosti 98
4.8.2. Odnos učinkovitosti upravljanja i indeksa ekonomske efikasnosti 100
4.9. Interpretacija rezultata istraživanja 102
4.10. Mogućnosti implementacije AOMP-a u informacijskim sustavima 104
4.10.1. Analiza omeđivanja podataka kao dio sustava poslovne inteligencije 106
4.10.2. AOMP kao web-aplikacija za analizu efikasnosti/učinkovitosti 112
5. ZAKLJUČAK 120

POPIS SLIKA

Slika 3-1: Model uravnoteženih ciljeva (Kaplan & Norton, 2000.) 19
Slika 3-2: Perspektiva internih procesa – model osnovnog lanca (Kaplan & Norton, 2000.) . 22
Slika 3-3: Okvir za mjerenje učenja i rasta (Kaplan, Norton 2000.) 23
Slika 3-4: Prevođenje misija, vizije i strategije u BSC-u (Niven, 2003.) 25
Slika 3-5: Prilagodba Balanced Scorecard okvira neprofitnim org. (Kaplan, 2001.) 26
Slika 3-6: Europski model poslovne izvrsnosti (EFQM-a) 31
Slika 3-7: RADAR model EFQM-a (www.efqm.org, prilagodio Bogović) 34
Slika 3-8: Razine izvrsnosti prema EFQM-u 35
Slika 3-9: Zajednički okvir za ocjenu organizacija u javnome sektoru 39
Slika 3-10: Grafički prikaz primjera AOMP 46
Slika 3-11. Granica efikasnosti prema BCC modelu 47
Slika 3-12: Prikaz granice efikasnosti prema CCR modelu (Rabar, 2010.) 51
Slika 3-13: Granica efikasnosti prema BCC i CCR modelu 53
Slika 3-14: Ilustracija DEA window analize (Savić, 2012.) 55
Slika 3-15: Grafički prikaz učinlovitosti prema modelima CCR i BCC (Vincova, 2005.) 57
Slika 4-1: Poslovi iz nadležnosti JLSU-a 68
Slika 4-2: Struktura upravljanja gradovima 2005. – 2008. godine 69
Slika 4-3: Prikaz normaliziranih pokazatelja 76
Slika 4-4: Distribucija učinkovitosti DO-a prema CCR modelu 81
Slika 4-5: Kontribucija u referentnom skupu 82
Slika 4-6 : Frekvencija pojavljivanja učinkovitih DO-a 83
Slika 4-7: Referentna usporedba Splita i uzornog grada Vinkovaca 88
Slika 4-8: Referentna usporedba Bjelovara i uzornog grada Velike Gorice 89
Slika 4-9: Input – output kontribucija Bjelovar 90
Slika 4-10: Input-output kontribucija Sisak 91
Slika 4-11: Korekcija indikatora za projekciju Bjelovara na granicu učinkovitosti 91
Slika 4-12 Korekcija indikatora za projekciju Siska na granicu učinkovitosti 92
Slika 4-13: Prikaz relativne učinkovitost prema diskrecijskim i nediskrecijskim ulazima 98
Slika 4-14: Pregled odnosa varijabli uključenih u istraživanje 103
Slika 4-15: Ciklus poslovne inteligencije 108
Slika 4-16: AOMP u sustavu poslovne inteligencije 110
Slika 4-17: Shema web-servisa za AOMP 118

POPIS TABLICA

Tablica 3-1: Značaj i vrjednovanja pokazatelja u EFQM modelu 32
Tablica 3-2: Tablica za procjenu kriterija prema EFQM-u 33
Tablica 3-3: Prikaz dodijeljenih nagrada u razdoblju od 1992. do 2009. godine 36
Tablica 3-4: Primjer AOMP s jednim ulazom i jednim izlazom 45
Tablica 3-5: Rezultat CCR efikasnosti 45
Tablica 3-6: Stupanj učinkovitosti prema CCR i BCC modelu 56
Tablica 4-1: Izvorni empirijski podaci 73
Tablica 4-2: Normalizirani podaci ulaza i izlaza 75
Tablica 4-3: Deskriptivna statistika ulaza i izlaza uključenih u model AOMP-a 77
Tablica 4-4: Matrica koeficijenata korelacije ulaza i izlaza 78
Tablica 4-5: Rezultati analize učinkovitosti upravljanja hrvatskim gradovima 80
Tablica 4-6: Skup referentnih gradova prema CCR modelu 82
Tablica 4-7: Ulazno – izlazna orijentacija (kontribucija) 84
Tablica 4-8: Projekcija na granicu uspješnosti korekcijom parametara 86
Tablica 4-9: Rezultati AOMP analize prozora 93
Tablica 4-10: Podaci o gradonačelnicima u mandatnom razdoblju od 2005. do 2008. 95
Tablica 4-11: Usporedba relativne učinkovitosti diskrecijskih i nediskrecijskih ulaza 97
Tablica 4-12: Odnos indeksa razvijenosti hrvatskih gradova i učinkovitosti upravljanja 100
Tablica 4-13: Odnos indeksa ekonomske efikasnosti i učinkovitosti upravljanja 101

KRATICE

AOMP – Analiza omeđivanja podataka

BCC – Banker – Charnes – Cooperov model

BDP – Bruto društveni proizvod

BI – Business Intelligence

BSC – Balanced Scorecard

CAF – Common Assessment Framework

CCR – Charnes – Cooper – Rhodesov model

CRS – Constant Return to Scale

DEA – Data Envelopment Analysis

DO – Donositelj odluka

DZS – Državni zavod za statistiku

EFQM – European Foundation for Quality Management

EIPA – European Institute of Public Administration

EQA – European Quality Award

EU – Europska unija

FDI – Foreign Direct Investments

HTML – Hyper Text Markup Language

HZMO – Hrvatski zavod za mirovinsko osiguranje

HZZ – Hrvatski zavod za zapošljavanje

IU – BCC – Izlazno usmjeren BCC model

IU – CCR – Izlazno usmjeren CCR model

JLSU – Jedinice lokalne samouprave

LER – Lokalni ekonomski razvoj

NBP – Nacionalna baza podataka

PI – Poslovna inteligencija

TQM – Total Quality Management

UN – Ujedinjeni narodi

UU – BCC – Ulazno usmjeren BCC model

UU – CCR – Ulazno usmjeren CCR model

VA – Value added

VRS – Variable Return to Scale

XML – EXtensible Markup Language

1. UVOD

Gradovi su u suvremenom ekonomskom poretku postali nositeljima društvenog razvoja, a trendovi povećanja koncentracije urbanoga stanovništva, proizvodno-potrošačkih kapaciteta i javnoga kapitala u gradovima, dodatno ističu važnost upravljanja javnim resursima na društveno odgovoran način. U cilju postizanja konkurentnosti i zadovoljavanja potreba širih interesnih skupina - javnih dionika, gradske su vlasti prinuđene ponašati se odgovorno koristeći se suvremenim menadžerskim alatima u cilju što učinkovitijega upravljanja vlastitim razvojnim potencijalima. Razmatrajući razvoj lokalne samouprave, brojni znanstvenici ističu kako su lokalne vlasti najčešće slijedile profitni sektor u pristupu konkurentnosti i upravljačkim procesima, nerijetko preuzimajući od njih i alate kojima se nastojalo mjeriti učinke i pratiti uspješnost poslovanja. Tako je početkom 70-ih godina prošloga stoljeća zamijećen trend transformacije gradskih uprava u kapitalističkome okruženju, od menadžerskih k poduzetničkim (Vujović, 2012.).

Do sredine dvadesetog stoljeća poslovna se uspješnost mjerila i iskazivala uglavnom financijskim pokazateljima koji su iskazivali uspješnost u razdoblju koje je prethodilo analizi, a vrijednost poduzeća iskazivala se materijalnom imovinom, dok suvremena ekonomska teorija, u sustavu glavnih vrijednosti poslovne organizacije, stavlja intelektualni potencijal zaposlenika (*nematerijalni resursi*) ispred materijalnih vrijednosti. Tomu svjedoče i promjene pristupa konkurentnosti u profitnom sektoru potkraj prethodnoga stoljeća u kojem su nematerijalni resursi sve više participirali u vrijednosti poduzeća, što je utjecalo na razvoj sofisticiranih menadžerskih alata (eng. *soft*) koje je ubrzo prihvaćao i neprofitni sektor (EFQM[1], CAF[2], BSC[3] i dr.). Iako se ne mogu mjeriti izravni učinci upravljanja lokalnim razvojem, performanse učinkovitosti upravljanja javnim resursima mogu se izraziti ekonomsko-gospodarskim pokazateljima u lokalnoj zajednici (Chen, 2010.) kojima se odražava interese širih društvenih skupina.

S mjerenjem i ocjenom učinkovitosti upravljanja javnim resursima na lokalnoj i regionalnoj razini započelo se ranih 90-ih godina prošloga stoljeća u gospodarski razvijenim, a desetak godina kasnije i u tranzicijskim zemljama (Marković i dr. 2008.), ali uz veliku raznolikost u

[1] European Foundation for Quality Management

[2] Common Assessment Framework

[3] Balanced Scorecard

metodološkom pristupu mjerenju. U posljednjih dvadeset godina važan pristup u analizi učinkovitosti u neprofitnom sektoru postala je metoda analize omeđivanja podataka *AOMP* (eng. *Data Envelopment Analysis, DEA*). Data envelopment analysis (DEA) u hrvatskoj se literaturi prevodi kao metoda analize omeđivanja podataka (AOMP ili AOP), a predstavlja tehniku neparametarskog linearnog programiranja koja se koristi za procjenu relativne učinkovitosti/efikasnosti jedinica za odlučivanje, odnosno donositelja odluka DO (eng. *Decision making units-DMU*) koje se koriste istim resursima (eng. *inputs*) i stvaraju iste učinke (eng. *outputs)*, a međusobno se razlikuju prema razini resursa kojima raspolažu i razini aktivnosti unutar procesa transformacije (Šporčić i ost., 2010.).

Premda u Hrvatskoj nema općeprihvaćenih alata za analizu učinkovitosti javnog sektora kao ni standardizirane metode za praćenje i ocjenu javne uprave, ovom će se metodom utvrditi relativnu učinkovitost upravljanja hrvatskim gradovima, izražena ekonomskim performansama lokalnog razvoja u odnosu na fiskalne resurse kojima lokalna vlast raspolaže. Rezultati istraživanja će pridonijeti identifikaciji skupa pokazatelja koji mogu u znatnoj mjeri pozitivno utjecati na učinkovitost upravljanja pojedinim gradom, a neučinkovitim će gradovima ukazati na pozitivne primjere iz prakse (eng. *benchmarking*[4]). Istraživanje provedeno u okviru ove doktorske disertacije poslužit će kao predložak za izradu koncepta javnoga web-servisa, kao podrške odlučivanju u javnoj upravi i sustava kontrole učinkovitog upravljanja javnim resursima.

1.1. Predmet istraživanja

S jedne strane dinamično društveno okruženje sve češće i glasnije postavlja pitanja učinkovitosti i društvene odgovornosti, dok s druge strane postavlja pitanja racionalizacije troškova lokalne samouprave ističući potrebu poreznog rasterećenja građana i gospodarstva (Wisniewski i Olafsson, 2004.). To je društveno proturječje imperativ lokalnom političkom menadžmentu da u sustav upravljanja uvede suvremene menadžerske alate i poslovne modele po uzoru na profitni sektor. Osim samoga političkog menadžmenta, kojemu je na izborima povjereno upravljanje lokalnom zajednicom, za mjerenje učinkovitosti zainteresirana je cijela zajednica (engl. *stakeholders*) i središnja država. Građani kroz porezna davanja financiraju

[4] *benchmarking* je proces mjerenja i uspoređivanja s najboljima unutar područja djelovanja ili izvan njega (preuzeto iz *Leksikona menadžmenta)*. U hrvatskom jeziku nema adekvatnog prijevoda pa će se u ovom radu koristiti u izvornom obliku.

javne usluge čijim se opsegom, kvalitetom i dostupnošću ocjenjuje učinkovitost korištenja javnih resursa. Javne su usluge usmjerene i poticanju lokalnog ekonomskog razvoja koji se očituje stvaranjem pretpostavki za gospodarski i društveni razvoj čime se krug zainteresiranih javnih dionika proširuje. „Vrijednost za novac“ postao je bitan aspekt lokalne samouprave kao jedan od čimbenika koji je dodatno potaknuo uvođenje sustava mjerenja u lokalnoj samoupravi (Palmer, 1993.).

Centre odlučivanja, odnosno donositelje odluka u lokalnoj samoupravi u Republici Hrvatskoj predstavlja politički menadžment koji potvrdu uspješnosti upravljanja javnim resursima traži na izborima te stoga po prirodi stvari nastoji upravljati što uspješnije i učinkovitije. Premda je politički pragmatizam često u suprotnosti s javnim interesima, postoji interes svih javnih dionika za jedinstvenim i nepristranim sustavom ocjenjivanja izvan političkog konteksta.

Stoga je opravdana usredotočenost javnosti na mjerenje i uspoređivanje učinkovitosti lokalne samouprave, odnosno lokalnih vlasti, kao skupa relativno homogenih i usporedivih ustrojstvenih jedinica koje djeluju u istim zakonskim i ekonomskim okvirima. Iako pojam učinkovitosti u javnoj upravi općenito nije jasno definiran i može se različito interpretirati, čini se najprirodnijim shvatiti ga kao omjer između raspoloživih resursa (eng. *inputs*) i ostvarenih učinaka (eng. *outputs*) (Emrouznejad, 2008.). Mjerenje apsolutne učinkovitosti kao omjera između postignutih i teoretski mogućih rezultata, u sektoru lokalne samouprave nije moguće s obzirom na to da:

- postoji više ulaza i izlaza koji se odnose na različite resurse, aktivnosti i okruženje,
- veza između ulaza i izlaza nije eksplicitna[5],
- određivanje težina ulaza i izlaza moguća je samo na subjektivnoj razini,
- različiti ulazi i izlazi izraženi su najčešće različitim mjernim jedinicama.

Istraživanjem učinkovitosti upravljanja velikim gradovima[6] u Republici Hrvatskoj nastojat će se utvrditi dostignuti stupanj učinkovitosti pojedinih gradova u odnosu na ostale iz skupine velikih gradova, uz korištenje metode analize omeđivanjem podataka (AOMP) koja nadilazi sva iznesena ograničenja i na osnovi poznatih empirijskih podataka o razini ulaza i izlaza

[5] Eksplicitna veza odražava odnos u kojem svaka kombinacija inputa pridružuje poznati skup mogućih outputa.

[6] Zakonom o izmjenama i dopunama Zakona o lokalnoj i područnoj (regionalnoj) samoupravi, NN 129/2005, čl. 19a, uvedena je posebna vrsta jedinica lokalne samouprave - *veliki grad* kao jedinice lokalne samouprave koje su ujedno gospodarska, financijska, kulturna, zdravstvena, prometna i znanstvena središta razvoja šireg okruženja i koji imaju više od 35.000 stanovnika.

računa za svaku jedinicu njezinu relativnu učinkovitost u odnosu na ostale promatrane. Prema Worthingtonu (2000. a) pokazatelji učinkovitosti lokalnih samouprava u izravnoj su korelaciji s njihovim osnovnim funkcijama, ali nema ni jednog sustava koji ih izravno može kvantificirati. Za potrebe istraživanja identificirani su ključni ulazi i izlazi koji odražavaju usklađene izvorne ovlasti velikih gradova s ciljevima istraživanja, a iskazuju se numerički u svim donositeljima odluka na isti način.

Prema Emrouznejadu, Parkeru i Tavaresu (2008.) na području primjene AOMP metode napisano je više od četiri tisuće znanstvenih radova, a znatan se dio njih odnosi upravo na neprofitni (javni) sektor. Unatoč brojnim istraživanjima i velikom interesu znanstvene javnosti, uočen je nedostatak metode u postupku odabira karakterističnih ulaza i izlaza ovisno o vrsti istraživanja, na što će planirano istraživanje nastojati odgovoriti. S druge strane opseg istraživanja u svezi s primjenom AOMP-a u neprofitnom sektoru u Republici Hrvatskoj je znatno siromašniji od istih analiza u profitnome sektoru, a u području procjene uspješnosti upravljanja gradovima (lokalnom samoupravom) do sada nema poznatih radova.

1.2. Svrha istraživanja

Istraživanje koje će se provesti u okviru ove disertacije ima zadatak utvrditi i međusobno usporediti uspješnost upravljanja velikim gradovima u Republici Hrvatskoj na osnovi ekonomskih pokazatelja. Međutim svrha ovog istraživanja je puno šira s duljom perspektivom a podrazumijeva razvoj nacionalnog metodološkog okvira koji će omogućiti unutarnje i vanjsko vrednovanje upravljanja javnim dobrima na jasan i svima dostupan način.

Za ocjenu učinkovitosti lokalnih vlasti, zbog različitih okolnosti i niza specifičnih čimbenika u kojima lokalna uprava obavlja poslove i u kojima se ostvaruju analizirani ekonomski pokazatelji, odabrana je metoda analize omeđivanjem podataka jer omogućuje istovremenu analizu više jedinica s više varijabli. AOMP će na osnovi odabranih ulaza i izlaza utvrditi relativnu učinkovitost za 15 velikih gradova u Republici Hrvatskoj, identificirati primjere učinkovitog upravljanja, a za neučinkovite će gradove odrediti izvore neuspješnosti kao mjesta mogućeg poboljšanja/racionalizacije te će im ukazati na uspješnu praksu iz okruženja (eng. *benchmarking)*. Ovo će istraživanje na objektivan način izlučiti primjere uspješnog i društveno odgovornog upravljanja lokalnom samoupravom, utvrditi ovisnost učinkovitosti upravljanja s razinom ekonomske razvijenosti gradova i refleksije učinkovitosti na razinu društveno-ekonomskog standarda.

Stoga će rezultati dobiveni ovim istraživanjem zadovoljiti interes javnih dionika i omogućiti realnu procjenu uspješnosti lokalnog menadžmenta u upravljanju javnim resursima i kvalitetu obavljanja javnih poslova i usluga, ali će isto tako pokazati političkom menadžmentu da se AOMP može koristiti kao važno strateško i organizacijsko oruđe.

U cilju unaprjeđenja metodike AOMP-a u analizi učinkovitosti lokalnih vlasti bit će korištene dvije vrste ulaza i to skupina kojom izravno upravlja DO – tzv. diskrecijski ulazi (l. *controllable*) i druga skupina koja je izvan ovlasti DO-a – tzv. nediskrecijski (eng. *uncontrollable*). Rezultati relativne učinkovitosti dobiveni u kombinaciji tih dviju skupina ulaza stavit će se u korelaciju s indeksom razvijenosti i indeksom ekonomske efikasnosti grada, u cilju utvrđivanja utjecaja odabranih ulaza na rezultate učinkovitosti ovisno o kontekstu istraživanja. Drugim riječima, na taj se način traži odgovor na pitanje može li se odabirom diskrecijskih ulaza usmjeriti istraživanje na ljudske resurse i na taj način suziti fokus istraživanja i povezati izvore (ne)učinkovitosti uz konkretne razine odlučivanja.

1.3. Ciljevi istraživanja i hipoteze

Cilj istraživanja:

- utvrditi učinkovitost upravljanja javnom upravom u Republici Hrvatskoj metodom analize omeđivanja podataka na osnovi ekonomskih pokazatelja,
    - identificirati primjere učinkovitog upravljanja gradovima, a za svaki neučinkoviti grad odrediti izvore neučinkovitosti kao mjesta mogućeg poboljšanja/racionalizacije i za svaki od njih odrediti primjere uspješne prakse iz okruženja (eng. *benchmarking*),
    - utvrditi povezanost učinkovitosti upravljanja s razinom ekonomske razvijenosti i gospodarskim potencijalom okruženja,
    - interpretirati dobivene rezultate efikasnosti kao mjeru postizanja zadanih ciljeva, odnosno učinkovitosti upravljanja,
- ukazati na moguća poboljšanja učinkovitosti upravljanja javnim resursima primjenom metode analize omeđivanja podataka,
    - znanstvenim pristupom ukazati na značaj primjene suvremenih menadžerskih spoznaja i alata u upravljanju javnim resursima,
    - utvrditi razinu kompatibilnosti AOMP alata sa sustavom poslovne inteligencije kao aplikacije i alata u sustavu potpore odlučivanju,

- izraditi koncept javnog web-servisa kao potpore odlučivanju u javnoj upravi i sustava kontrole učinkovitoga upravljanja javnim resursima,

- utvrditi veze između odabira karakterističnih performansi, utjecaja okruženja u kojima djeluje određeni DO i povezanosti sa strateškim ciljevima, kao doprinos unaprjeđenju metodike AOMP-a, odnosno utvrditi utjecaj razine diskrecije ulaza i povezanosti rezultata sa zadanim ciljevima na individualizaciju rezultata relativne učinkovitosti.

Hipoteze:

H I:

Uspješnost jedinica lokalne samouprave u Republici Hrvatskoj, izražena ekonomskim performansama, povezana je s upravljačkim kompetencijama političkog menadžmenta.

H II:

a) Analiza omeđivanja podataka omogućuje generiranje informacija bitnih za učinkovito upravljanje javnim resursima, a javnim dionicima omogućuje procjenu kvalitete političkoga menadžmenta.

b) Upotrebom metode analize omeđivanja podataka može se poboljšati učinkovitost upravljanja javnim resursima.

H III:

Analiza omeđivanja podataka može biti platforma za razvoj javnog web-servisa za (samo)ocjenu učinkovitosti upravljanja javnim resursima.

H IV:

Doprinos ljudskih potencijala u ostvarenim rezultatima učinkovitosti je veći u slučaju odabira diskrecijskih karakterističnih ulaza.

1.4. Doprinos istraživanja

S obzirom na dualno postavljene ciljeve, one povezane s analizom učinkovitosti upravljanja hrvatskim gradovima i povezanosti diskrecijske razine ulaza s usmjerenošću rezultata na ljudske potencijale u centrima DO-a, rezultati istraživanja i sklopu ove doktorske disertacije dati će dvojaki doprinos. Unaprjeđenje postupka odabira ključnih ulaza, ovisno o kontekstu istraživanja, kao doprinos razvoju metodike AOMP-a, dok će rezultati istraživanja učinkovitosti upravljanja omogućit objektivno sagledavanje uloge lokalnih vlasti u kreiranju razvojnih politika koje se odražavaju na prosperitet cijele zajednice. Potvrđivanje pretpostavki o nepostojanju korelacije između učinkovitosti upravljanja i stupnja gospodarskog razvoja,

odnosno količine resursa koji su lokalnoj vlasti na raspolaganju u realizaciji razvojnih politika i obavljanju poslova iz svojih ovlasti, neizravno će imati utjecaj na razvoj svijesti o prednostima izbora kompetentnih i motiviranih u odnosu na politički etablirane gradske menadžere. To će ukazati na dominantan utjecaj lokalnog menadžmenta u stvaranju prosperiteta zajednice i rušenju društvenih tabua da su neki gradovi i sredine predodređene na uspješnost, a druge na zaostajanje u razvoju. Osim navedenog, spoznaja samih političkih struktura koje upravljaju gradovima o vlastitim rezultatima i mogućim dosezima u odnosu na postignute rezultate, omogućit će napredak i dodatno motivirati gradonačelnike na prihvaćanje menadžerskih alata kao efikasne podrške planiranju i upravljanju. Postupci, koji se predlažu u ovome istraživanju, bit će pomoć gradskim vlastima u otkrivanju izvora (ne)efikasnosti, određivanju njihova značenja u realizaciji ciljeva te identificiranju strategija koje će doprinijeti učinkovitijemu upravljanju. Također mogu biti i katalizator u smislu širenja uspješnih primjera i efikasnih postupaka na područja u kojima se mogu primijeniti.

S obzirom na to da u Hrvatskoj još nije uveden ni jedan model ocjene učinkovitosti lokalne samouprave, ovaj će rad doprinijeti razvoju nacionalnih metodoloških okvira (modela i metoda) za praćenje i ocjenjivanje upravljanja javnim sektorom u Republici Hrvatskoj. Ocjena učinkovitosti upravljanja gradovima ukazat će na mogućnosti primjene analize omeđivanja podataka i u drugim ustrojstvenim jedinicama na lokalnoj i regionalnoj razini kao i u drugim subjektima iz neprofitnog sektora. S obzirom na mali broj znanstvenih uradaka o upotrebi metode AOMP u Hrvatskoj i općenito izražen nedostatak znanstvenih istraživanja na području ocjenjivanja učinkovitosti javnog sektora, ovaj će rad nedvojbeno imati određen znanstveni doprinos.

Očekuje se da će provedeno znanstveno istraživanje doprinijeti razvoju nacionalnih metodoloških okvira za praćenje i ocjenjivanje upravljanja javnim resursima i utvrditi u kojoj je mjeri moguće standardizirati metodologiju ocjene učinkovitosti upravljanja javnim resursima na osnovi AOMP metode. Rezultati istraživanja i dobivene znanstvene spoznaje poslužit će kao osnova za kreiranje javnog web-servisa za samo(ocjenu) i praćenje učinkovitosti upravljanja javnim resursima. Rad će prikazati mogućnosti primjene AOMP-a kao snažne podrške planiranju i upravljanju u javnom sektoru, koji pruža menadžmentu niz korisnih informacija važnih za povećanje učinkovitosti upravljanja, a unaprjeđenje postupka odabira ključnih pokazatelja, ovisno o kontekstu istraživanja, doprinijet će razvoju metodike AOMP-a.

2. UČINKOVITOST UPRAVLJANJA LOKALNOM SAMUPRAVOM

2.1. Uloga gradova u gospodarskom razvoju

Da urbane razvojne politike, poglavito gospodarske, imaju temeljno značenje u kreiranju odgovora na svjetske izazove poput globalizacije i urbanizacije govore podatci o povećanju udjela urbanog stanovništva i dominacije urbane ekonomije u stvaranju nacionalnih dohodaka. Percepcija nacionalnih ekonomija i uloge države u kreiranju vlastitoga gospodarskog razvoja u korist decentralizacije odgovornosti i upravljanja gospodarskim razvojem na niže ustrojstvene jedinice promijenila se u posljednja tri desetljeća 20. stoljeća. Globalna ekonomija potiče razvoj supranacionalnih korporativnih struktura i umanjuje značaj nacionalnih država uz istovremeno jačanje lokalnih i regionalnih ekonomsko-političkih nivoa regulacije (Knox, 1995.). Zašto se stabilnost i razvoj nacionalnih ekonomija sve više oslanja na razvoj gradova i do koje razine decentralizacije produktivno utječe na opći društveni razvoj te koja je uloga državne i lokalne vlasti u gospodarskom razvoju, središnja su pitanja brojnih istraživanja i znanstvenih rasprava (Coulson, 1997., Shirin&Sundeep, 2001., Bartik, 2003., Petrović, 2004., Stoker, 2006. i dr.). Opredjeljenje nacionalnih ekonomija na jačanje uloge gradova u gospodarskom razvoju objašnjava tvrdnja prema kojoj jačanje političke i ekonomske uloge gradova nije inkompatibilno s razvojem nacionalne ekonomije već je, naprotiv, jačanje konkurentnosti i kompetitivnosti gradova povezano s jačanjem nacionalnih ekonomija (Scott, 2002.). Razina nacionalne svijesti u potenciranju lokalnog razvoja odražava se stupnjem decentralizacije i samostalnosti lokalnih zajednica u vođenju vlastite politike razvoja. Premda gradovi pokazuju znatniju adaptabilnost na promjenjivo ekonomsko, socijalno i funkcionalno okruženje od nacionalnih država (Castells, 1993.), većim stupnjem decentralizacije nacionalne ekonomije postaju stabilnije i konkurentnije. Implicitno, društveno je političko okruženje u kojem se razvijaju gradovi to opstruktivnije što je stupanj centralizacije izraženiji. Dakle, veza između urbanizacije i gospodarskog razvoja je nedvojbena pri čemu je uloga središnje države u planiranju i provedbi politike ekonomskog razvoja obrnuto proporcionalna povećanju samostalnosti i odgovornosti gradova, kako za vlastiti tako i za nacionalni razvoj. Ukratko, nacionalni je ekonomski razvoj sinergetski učinak ukupnosti lokalnih razvojnih dostignuća kao lanca, čija najtanja karika ne bi smjela biti slabija od nacionalne razine. Iako je takav ideal teško pronaći u praksi, težnja ostvarenju ujednačena regionalnog razvoja jest paradigma svih nacionalnih zajednica bez obzira na stupanj ekonomskoga razvoja.

Bez obzira na činjenicu što je razvoj informacijskih i transportnih tehnologija utjecao na gotovo neograničenu mobilnost tehnologija i znanja kao i manju ovisnost gospodarstva o fizičkoj lokaciji, analitičari i znanstvenici ističu sve značajniju ulogu gradova u svim aspektima globalizacije, a poglavito u gospodarskome (Zhang, 2002; Petrović, 2004.). U prilog iznesenome idu i podatci o permanentnom povećanju broja urbanoga stanovništva koje je prema službenim podatcima UN-a[7] za 2005. godinu iznosilo 49% na svjetskoj razini, odnosno 72% na europskoj razini. Migracijski tokovi prema urbanim sredinama utječu na teritorijalno proširenje gradova i povećanje gravitacijskog utjecaja urbane politike na područja koja nisu karakteristično urbana (*suburbanizacija*). Takva velika koncentracija radne snage i gospodarskih subjekata promiče ekonomsku uspješnost širenjem informacija među investitorima/gospodarstvenicima i regulacijom tržišta radne snage, odnosno smanjenjem transportnih troškova ulaza i finalnoga proizvoda (Henderson, 2000.). Iako se industrijalizacija i visoka koncentracija radnih mjesta u gradovima smatra glavnim pokretačem migracija, neki pak znanstvenici smatraju da lokacija poduzeća determinira lokaciju grada, odnosno nastanak gradova povezuju s koncentracijom zaposlenosti (Tica, 2004.). Povećanje udjela urbanoga stanovništva u Republici Hrvatskoj prati svjetske trendove što utječe i na fizički porast gradova[8]. U velikim gradovima u Republici Hrvatskoj[9] i Gradu Zagrebu živi 41,82% stanovništva[10], a u njima se stvara 74,43% od ukupno novostvorene vrijednosti[11] (VA) na nacionalnoj razini. Sukladno iznesenomu, procesi urbanizacije i globalizacije doprinose ekonomskom jačanju gradova, ali pri tome, s jedne strane, pred gradske vlasti stavljaju sve veće zahtjeve i izazove u stvaranju uravnotežena okruženja za gospodarske subjekte te, s druge strane, ugodna mjesta za život.

---

[7] Urban Population Development and the Environmental 2007, UN 2008

[8] Vresk (1992) ukazuje na migracijske trendove koji doprinose povećanju udjela urbanog stanovništva u Republici Hrvatskoj pa je tako 1991. godine u gradovima živjelo 51,7% stanovnika, a deset godina kasnije 63%. Podatak da 1900. godine u Hrvatskoj nije bio ni jedan grad s više od 100.000 stanovnika, a prema popisu stanovništva iz 2001. godine u gradovima s više od 100.000 stanovnika živjelo je 27% stanovništva ukazuje na rast velikih gradova, unatoč smanjenju ukupnog broja stanovnika.

[9] Zakonom o izmjenama i dopunama Zakona o lokalnoj i područnoj (regionalnoj) samoupravi, NN 129/2005, čl. 19a, uvedena je posebna vrsta jedinica lokalne samouprave - *veliki grad*. Veliki gradovi su jedinice lokalne samouprave koje su ujedno gospodarska, financijska, kulturna, zdravstvena, prometna i znanstvena središta razvitka šireg okruženja i koji imaju više od 35.000 stanovnika.

[10] Prema DZS; *Popis stanovništva 2001.;* u 15 gradova, sa >35.000 stanovnika, živi 1.076.810 stanovnika

[11] Intelektualni kapital; *Uspješnost na nacionalnoj, županijskoj i poduzetničkoj razini 2006.*

2.2. Lokalni ekonomski razvoj i razvojne politike

S obzirom na prikazano povećanje značaja gradova u općem društvenom razvoju, pitanje uspješnog, društveno odgovornog i za dulje vremensko razdoblje prihvatljivog ekonomskog razvoja pobuđuje sve veći interes znanstvenih i društvenih krugova (Čavrak, 2003.). Lokalni ekonomski razvoj (LER) predmet je mnogih istraživanja i izučavanja na visokim znanstvenim institucijama na razini teorijskih i empirijskih spoznaja (Boyine, 1988.; Foley i ost., 1996.; Lubna, 1998.; Bartik, 2003.; Čapkova, 2005 i dr.). LER se može u najširem obliku opisati strategijom u kojoj se lokalna vlast i ostali dionici/akteri nastoje na optimalan način koristiti raspoloživim resursima u cilju očuvanja postojećih kapaciteta i stvaranja pozitivnog poslovnog okruženja za razvoj novih gospodarskih investicija. U svojoj knjizi o planiranju ekonomskog razvoja Edward J. Blakely (2003.) definira lokalni ekonomski razvoj kao proces kojim lokalna vlast i/ili lokalni akteri upravljaju postojećim resursima te ih kroz partnerski odnos s privatnim sektorom angažiraju u cilju otvaranja novih radnih mjesta i poticanja novih ekonomskih aktivnosti u dobro organiziranim gospodarskim zonama. Stevens i McGowan (1987.) ističu da je lokalni ekonomski razvoj primjer kompleksnog, otvorenog i interaktivnog okruženja u kojem konkurentna dobra države, privatnog sektora, građana i drugih lokalnih samouprava nastoje stvoriti okruženje za jačanje konkurencije. Iz konteksta istraživanja kojim se bavi ovaj rad, LER se može podvesti pod zajednički nazivnik: *lokalna vlast-upravljanje i raspolaganje raspoloživim resursima*.

Gradovi nemaju jednake potencijale za razvoj i na različite se načine koriste resursima u upravljanju razvojem što ih čini više ili manje uspješnima. Osnovna je pretpostavka uspješnosti lokalne samouprave u upravljanju vlastitim, a time i nacionalnim razvojem, artikulacija općih interesa zajednice[12] u kratkoročnim i dugoročnim razvojnim politikama. Lokalne se razvojne politike mogu definirati kao posebne aktivnosti poduzete od javnih ili privatnih grupa u cilju unaprjeđenja ekonomskog razvoja (Bartik, 2003.). On razvojne politike usmjerene lokalnomu gospodarskom razvoju grupira u dvije osnovne kategorije:

1. provedba ciljanih pomoći usmjerenih individualnim poduzetnicima koji na taj način ostvaruju veće ekonomske koristi i
2. strateške promjene porezne politike, potrošnje i regulatornih politika u cilju unaprjeđenja lokalnoga ekonomskog razvoja.

[12] Prema Hayeku (2001.) opći interes zajednice nije apstraktni ideal kojemu svi teže, nego zbir najvećega broja pojedinačnih interesa ili "opća svrha" kojoj građani teže.

Eisinger (1988.) klasificira razvojne politike također u dvije osnovne grupe: politike usmjerene povećanju gospodarske aktivnosti (eng.–*supply-side policies*) i aktivnosti usmjerene tržišnoj regulaciji (eng.–*demand-side policies*) i tom se klasifikacijom koristi velik broj ekonomskih teoretičara i znanstvenika. Razvojne su politike gradova najčešće odraz opredjeljenja lokalne vlasti koje inkliniraju prema jednoj od navedenih podjela, ali imaju svoje specifičnosti ovisno o prilikama u kojima se pojedina lokalna zajednica razvija i proaktivnosti lokalne vlasti. Pri tome znatnu ulogu ima premoć političkoga liderstva nad menadžmentom/liderstvom (eng.–*management/leadership*) u upravljanju društvenim resursima.

2.3. Razvojni potencijali i konkurentnost gradova

Svjesni činjenice da lokalni razvoj nije moguće promatrati izvan širega društveno-političkog konteksta u kojem dominantnu ulogu ima država, nameće se osnovno pitanje u kojoj mjeri lokalna zajednica može upravljati svojim razvojem. Međusobni utjecaj različitih razina vlasti na lokalne razvojne politike i uspješnost gospodarskog razvoja istraživali su Stevens i McGowan na području Pennsylvanie[13] 1987. godine. Uz pretpostavke da je moguće identificirati obrasce snage lokalnog ekonomskog razvoja utvrdili su čvrstu vezu između menadžerskih strategija[14], učinkovitosti i ekonomskih razvojnih potencijala. Prema istim autorima razvojne su strategije viših razina (regionalne, državne) inferiorne u odnosu na lokalne razvojne politike koje su u znatnoj mjeri određene usmjerenošću sasvim određenim projektima uz mogućnost prilagodbe svakoj lokalnoj specifičnosti (Stevens i McGowan, 1987.). U prilog tomu idu i zapažanja Oatesa (1993.) koji ukazuje na to da su politike usmjerene osiguranju infrastrukture i ljudskih potencijala, osjetljive na lokalne uvjete, pogodnije i uspješnije u poticanju ekonomskog razvoja nego nacionalne politike koje zanemaruju geografske različitosti. S druge strane velika skupina znanstvenika (Begg, 1999.; Camagni, 1999.; Kresl& Singh, 1999. i dr.) zastupa stajalište da atraktivnost i konkurentnost gradova (lokacija) ne ovisi samo o „tvrdoj“ infrastrukturi već jednako tako i o „mekim“ sociopolitičkim uvjetima kao što su efikasnost politike razvoja, urbana strategija, suradnja javnoga i privatnoga sektora, kvaliteta života, inovativni potencijali i druge.

[13] Pennsylvanya je savezna država u SAD-u s 12 milijuna stanovnika, 52 grada, 14 gradova ima više od 35.000 stanovnika

[14] U Penssylvanyi gradska vlast vodi *city manager* u funkciji gradonačelnika, stoga do punoga izražaja dolazi strateški i operativni menadžment.

Uz pretpostavku da prioritet gradova nije samo egzogeni razvoj, interes se pomiče na međusobnu konkurentnost gradova na tržištu gospodarskih investicija i poželjnosti za život, kao izravnih čimbenika koji utječu na urbanizaciju. Potaknuti novonastalim uvjetima liberalizacije europskog i svjetskog tržišta brojni znanstvenici istražuju komponente urbane konkurentnosti (Casson, 2002., Bailey, 1999. i dr.). Osnovna je premisa istraživanja konkurentnosti gradova zasnovana na specifičnostima pojedine zajednice i specijalizaciji koja utječe na strukturiranje servisnih institucija i angažiranosti raspoloživih resursa (Blakely, 2002., Begg, 1999.). Promatrano kroz vrijeme, različiti su gradovi formirali različite institucionalne oblike, mreže postojećih gospodarstvenika ovisnih o lokalnoj ekonomiji, kulturi i političkoj praksi što je utjecalo na različitu ulogu koju određeni grad ima u ekonomskom razvoju (Naudei Krugell, 2002.). Oni su istraživali razliku gradova i njihove uloge u ekonomskome razvoju južne Afrike uzimajući u obzir utjecaj prosječnog godišnjeg ekonomskog rasta na smanjenje siromaštva. Suprotno neoklasičnomu modelu ekonomskog rasta[15], na istraživanom su uzorku od 353 lokalne jedinice južne Afrike ustvrdili da se visoko urbanizirane i gusto napućene sredine brže razvijaju od manjih i siromašnih, neovisno o politici razvoja i stupnju decentralizacije. Razrješenju pitanja ima li doista sama urbanizacija presudni utjecaj na razvoj i u Republici Hrvatskoj ili tomu u znatnoj mjeri doprinosi inovativnost i kompetentnost lokalne vlasti artikulirana u razvojnim politikama doprinijet će planirano istraživanje u sklopu ovoga rada.

2.4. Utjecaj upravljanja na gospodarski razvoj gradova

Utjecaj lokalne vlasti i njihovih razvojnih politika na lokalni ekonomski razvoj u svijetu istraživali su mnogi znanstvenici i teoretičari ekonomske, politološke i sociološke provenijencije (Deller, 1993.; Fu-Lai Yu, 2000.; Feiock & Jae-Hoon Kim, 2001.; Madon, 2001.; Bartik, 2003.; Bennett, 2004.; Mayer – Stamer, 2004.; Čapkova, 2005.; Martell & Guuess, 2006.; Mawson 2007., Eckardt, 2007. i dr.) Zajedničko je svim navedenim istraživanjima akcentuiranje planiranog i upravljanog lokalnog razvoja i u tome aktivna (vodeća) uloga lokalne vlasti. Iako lokalna vlast (*politika*) često opće društvene interese podređuje razvoju vlastite karijere i očuvanju pozicije (Blair, 1994.), upravljanje je lokalnim društvenim razvojem kompleksna i odgovorna uloga koja je dodatno opterećena diskontinuitetom vlasti i kratkoročnim dosegom planiranih razvojnih politika. Poglavito u

[15] Prema Solowu neoklasični model rasta pretpostavlja brži rast siromašnijih država (regija, gradova) od bogatijih. (Prema Naude – Krugell, 2002.; 15)

politički turbulentnim okolnostima, u kakvima se još uvijek nalazi Republika Hrvatska, razvojne politike imaju kratke horizonte, a lokalna vlast svoje odluke donosi u cilju postizanja rezultata „na kratke staze“ zanemarujući pri tome dugoročnu problematiku i potencijale zajednice.

2.5. Osnovna obilježja upravljanja gradovima u Republici Hrvatskoj

Upravljanje lokalnom samoupravom u Republici Hrvatskoj u proteklome desetogodišnjem razdoblju obilježilo je nekoliko bitnih stvari. U lokalnome zakonodavstvu[16] 2007. godine uveden je neposredan izbor općinskoga načelnika, gradonačelnika, župana i gradonačelnika Grada Zagreba, za razliku od dotadašnjega sustava posrednoga izbora od strane predstavničkoga tijela. Na taj je način odgovornost za upravljanje gradovima personalizirana i jasno definirana, a većina poslova iz ovlasti dotadašnjeg gradskog poglavarstva prenesena je na gradonačelnika uz ograničeno raspolaganje imovinom gradova. Osim tih bitnih zakonskih promjena, gradove, kao dio sustava lokalne samouprave u Republici Hrvatskoj, još uvijek obilježava nestabilnost, neuravnoteženost, nedovoljna efikasnost i slabi razvojni potencijali (Koprić, 2010.). Unatoč nastojanjima da se povećaju kapaciteti jedinica lokalne samouprave decentralizaciju ovlasti uglavnom nije pratila decentralizacija ostvarivanja prihoda, pa se zbog preopterećenosti proračuna smanjuje njihova neovisnost i samostalnost. Resursi kojima upravljaju gradonačelnici i načelnici su ograničeni i neravnomjerno raspoređeni pa središnja država nastoji ujednačiti neravnomjeran razvoj pomoćima iz državnoga proračuna područjima od posebnoga interesa i gospodarski nerazvijenim jedinicama lokalne samouprave kao i pomoći onima čiji prihodi nisu samodostatni[17] za obavljanje svih poslova iz njihovih ovlasti. Ako se, s jedne strane, u analizu uključe rashodi za zaposlene u lokalnoj samoupravi kao indikator intelektualnog potencijala te, s druge strane, primarnoga troška, slika o razvojnim potencijalima i učinkovitosti javne uprave postaje jasnija. Naime prema podacima Instituta za javne financije[18] broj zaposlenih u gradovima Republike Hrvatske povećao se u proteklom četverogodišnjem razdoblju za 21%, a rashodi su za zaposlene porasli za 23,7% uz istovremeni pad vlastitih prihoda. Time je saldo rashoda postao još negativniji, a učinkovitost upravljanja manja jer gradovima ostaje sve manje novca za razvojne projekte i obavljanje

16 Zakon o izborima općinskih načelnika, gradonačelnika, župana i gradonačelnika Grada Zagreba, Narodne novine broj: 109/07, 125/08, 24/11, 150/11 i Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, Narodne novine broj: 33/01, 60/01, 129/05, 109/07, 125/08, 36/09, 36/09, 150/11, 144/12, 19/13

17 Od ukupno 555 jedinica lokane samouprave u Republici Hrvatskoj, njih 240 vlastitim prihodima pokriva rashode s više od 75%, 150 pokriva rashode od 50% do 75%, a s manje od 50% vlastitih prihoda

18 NEWSLETTER, povremeno glasilo Instituta za javne financije, broj 71, 2012.

osnovnih funkcija bez dodatnoga zaduživanja. Nerijetko se pod utjecajem političkog pragmatizma gradovi nekontrolirano zadužuju[19] za realizaciju projekata koji potvrđuju političku opciju na vlasti. Rast obveza uz ograničene prihode gradova, negativno utječe na njihovu likvidnost, a posredno i na fiskalnu održivost cjelokupnoga lokalnog javnog sektora. S obzirom na to da gradovi kao većinski vlasnici javnih komunalnih tvrtki i kao osnivači javnih ustanova u kulturi, prosvjeti i športu, odgovaraju za njihovo financijsko poslovanje, sve njihove obveze i zaduživanja čine konsolidiranu bilancu još negativnijom. Gradovi su teret zaduživanja za izgradnju komunalne infrastrukture i kapitalnih projekata prebacivali na svoje tvrtke, i na taj način izbjegavali ishođenje potrebne suglasnosti središnje države za zaduživanje jedinice lokalne samouprave, i dio tereta društvenoga razvoja prebacili na komunalna poduzeća koja trošak pokrivaju iz ostvarene dobiti u distribuciji komunalnih usluga. Na taj su način lokalne vlasti dio tereta javnoga razvoja ukalkulirali u cijenu komunalnih usluga i dodatno (parafiskalno) opteretili svoje građane. Dakle utjecaj se izvršne vlasti (gradonačelnika) na kreiranje i realizaciju razvojnih politika može promatrati u širem kontekstu i izvan financijskoga okvira proračuna JLSU što, dakako, implicira i veću odgovornost na učinkovitost na cijelo područje utjecaja lokalne vlasti.

Iz navedenoga se može zaključiti da je upravljanje gradovima u Republici Hrvatskoj obilježeno sve većim opterećenjima proračuna, padom izvornih proračunskih prihoda, povećanjem zaduženosti i proračunskoga deficita dakle, ukratko, padom fiskalnoga potencijala lokalne samouprave.

Nestabilnost i česte promjene vlasti tijekom mandata na lokalnim razinama, uključujući i koaliranje „svih sa svima“, utjecali su na gubitak povjerenja kod građana, ali, što je još važnije za ovaj rad, uzrokovale su štete od političkoga pragmatizma i nesnalaženja u obnašanju vlasti. Diskontinuitet vlasti i kratkoročnost razvojnih politika, izostanak strategija i dugoročno održivih planova razvoja lokalnim su zajednicama u Republici Hrvatskoj znatno ograničenje u racionalnome i društveno odgovornom upravljanju javnim resursima. Sve to utječe na smanjenje razvojnih potencijala i nužne prilagodbe vlasti u lokalnoj samoupravi za primjenu suvremenih menadžerskih alata i spoznaja koje mogu doprinijeti povećanju učinkovitosti upravljanja javnim resursima.

[19] Ukupan izravan dug jedinica lokalne samouprave u 2008. godini iznosio je 2,7 mlrd. kuna, a u 2009. godini 2,94 mlrd. kuna (Ekonomski institut Zagreb).

2.6. Vodstvo i učinkovitost upravljanja gradovima

Predgovor svoje knjige „Biblija modernog vođe“ Velimir Srića (2004.) započinje riječima:“Na čelu svakog uspješnog sustava naći ćemo dobrog vođu – pobjednika. Manje uspješnim sustavima upravljaju manje dobri vođe. Loše sustave u pravilu vode loši vođe – gubitnici. Najveće sportske, povijesne, gospodarske, političke, znanstvene i umjetničke pobjede ostvaruju timovi kojima upravljaju pobjednici.“ Vodstvo ili Leadership (eng.) u poslovnome se svijetu posljednjih nekoliko desetljeća ističe kao ključ uspjeha, a veliki i uspješni sustavi ne mogu se zamisliti bez velikih vođa. Vođa posjeduje karizmu kojom motivira suradnike, pokreće projekte, ima viziju i upravlja promjenama. Ciljevi vođe u profitnom i neprofitnom sektoru su različiti. Dok u profitnome sektoru lideri nastoje ostvariti što veći profit vlasnicima kapitala, politički lideri uglavnom žele ponovo dobiti izbore. Prema Osbornu i Gaebleru (1992.), za razliku od privatnoga sektora, javni se sektor oslanja na porezne prihode ubrane od građana i gospodarstva pa ih u radu rukovodi pitanje zadovoljavaju li potrebe svojih korisnika i jesu li po ukusu svojih birača, ne zaboravljajući pri tome zadovoljenje očekivanja interesnih skupina koje ih podupiru. Da je liderstvo u javnome i neprofitnome sektoru jedan je od najvažnijih čimbenika njegova razvoja ističu Nanus i Dobbs (1999.), a s porastom značaja gradova u globalnome svijetu mijenja se i uloga koju imaju gradonačelnici – lokalni lideri. Tako o njihovim liderskim sposobnostima ovisi prosperitet i razina gradske ekonomske aktivnosti, što se izravno odražava na značaj grada u okruženju (Vujović, 2012.) i time utječe na učinkovitost upravljanja. Istražujući ulogu lidera i uspješnosti gradova Nordijskih zemalja Goldsmith i Larsen (2004.) zaključuju da (politički) lideri – gradonačelnici igraju presudnu ulogu u održavanju konzistentnosti lokalnih razvojnih politika.

Utjecaj liderskih sposobnosti lokalnoga političkog vodstva nije jednostavno definirati i kvantificirati, ali se on može neizravno izraziti učincima koje stvaraju u odnosu na količinu materijalnih resursa. U domeni je lidera definiranje vizije i strategije koju niže rangirani menadžeri i službenici provode u jasne i mjerljive ciljeve. Dakle politički lideri kreiraju promjene kroz razvojne politike i strateški menadžment, a razina je racionalnosti u oprjeci s političkim procesima koji često prevladavaju u lokalnoj samoupravi.

Vođe u domeni istraživanja učinkovitosti upravljanja velikim gradovima u Republici Hrvatskoj najviše su pozicionirani politički menadžeri – gradonačelnici. Njihov je utjecaj na kreiranje strateških ciljeva, motivaciju suradnika i niže rangiranih službenika u dosezanju tih

ciljeva presudan za postizanje izvrsnosti i kontinuirani napredak. Nerijetko se pod utjecajem izvrsnih vođa na pozicijama gradonačelnika identificiraju i gradovi lideri u svojem okruženju čiji primjeri poticajno djeluju i na druge lokalne vlasti (eng.–*benchmarking*).

Vođa – gradonačelnik je kreator promjena čiji se efekti iskazuju postignutim učincima na operativnoj razini, a ovise o uključenosti svih provoditelja. Stoga vođa mora inspirirati svoje suradnike koji sudjeluju u realizaciji vizije i strategije i „pridobiti ljude“ u okruženju koje je po prirodi inertno i nesklono promjenama. Podrška ili otpor inicijativama lidera u javnoj upravi su izbor koji ovisi o sljedećim čimbenicima:

- javna uprava zbog inertnosti po prirodi nije sklona promjenama, a zaposlenici iz iskustva o bezbrojnim pokušajima i neuspjelim promjenama pružaju znatan otpor,
- protok informacija zbog strukturalnih i organizacijskih poteškoća, kao i složeni birokratski postupci koji nameću kruta pravila, često pobune organizaciju protiv promjena,
- zbog iskustva iz prijašnjih radnih odnosa, (ne)znanja i (ne)snalaženja vođe u javnoj upravi ograničeno i pristrano (politički) postupaju u rješavanju poslova iz domene organizacije,
- političke preprjeke koje proizlaze iz sukoba s političkim centrima moći često rezultiraju opstrukcijom, neprosljeđivanjem informacija, osobnim konfliktima, nesuradnjom među upravnim tijelima unutar grada i opstrukcijom svih aktivnosti jedne političke opcije,
- vremensko ograničenje i politički pragmatizam favoriziraju postizanje operativnih dnevnopolitičkih ciljeva na štetu strateških ciljeva i vizija.

Stoga uspješno vođenje i upravljanje gradovima zahtijeva snažne i karizmatične osobe koje mogu i znaju pokrenuti promjene i utjecati na ponašanje drugih ljudi i savladavanje otpora. Vođe koji upravljaju centrima odlučivanja u gradovima imaju najveću moć, ali i najveću odgovornost za učinkovitost upravljanja. Oni moraju s mnogo znanja i umijeća upravljati jedinicom lokalne samouprave, kreirati promjene, artikulirati ih kroz strateške i operativne ciljeve i na kraju potaknuti pozitivnu energiju i iskoristiti intelektualni kapital koji posjeduju zaposlenici da bi ostvarili zadane ciljeve. Dakle proces se upravljanja ne smije svesti samo na materijalne resurse nego i na intelektualni kapital koji se uspješnim vođenjem može razvijati i pozitivno utjecati na povećanje učinkovitosti, ali se, jednako tako, pod utjecajem lošega vođe može potpuno obezvrijediti.

3. PRIKAZ METODA ZA MJERENJE UČINKOVITOSTI LOKALNE SAMOUPRAVE

Veća očekivanja od svih razina vlasti i povećana odgovornost prema javnim dionicima, još u ranim 80-im godinama prošloga stoljeća, potaknula su pitanje učinkovitosti i djelotvornosti nositelja vlasti i aktualizirala problematiku mjerenja uspješnosti njihova upravljanja (Hood, 1995). Stoga je mjerenje učinkovitosti upravljanja i vrjednovanje političkih programa središnje pitanje za učinkovite i odgovorne javne uprave (Guthrie i English, 1997.), a razlozi za kvantificiranje učinaka lokalnih vlasti postaju sve brojniji s povećanjem opsega poslova i ovlasti lokalne samouprave. Iz opusa znanstvene literature mogu se izdvojiti najvažniji:

- ocjena performansi lokalne samouprave omogućuje usporedbu u skupini sličnih jedinica i procjenu relativne učinkovitosti (Farrell, 1957.),
- mjerenjem učinkovitosti dobivaju se i pokazatelji neučinkovitosti u skupu jedinica koje se vrjednuju, što omogućuje poduzimanje aktivnosti za njihovo uklanjanje,
- zaključci takve analize mogu imati praktične političke implikacije u donošenju odluka u cilju poboljšanja učinkovitosti (Lovell, 1994.),
- ocjena učinkovitosti građanima, koji imaju osjećaj da se javna sredstva ne koriste uvijek na učinkovit i djelotvoran način, omogućuje transparentnost i javni nadzor (Moesen, 1994.).

Prema Yu-Chuanu i suradnicima (2010.) dva su osnovna pristupa u mjerenju učinkovitosti na lokalnoj razini. Prvi je zasnovan na statističkom pristupu procjeni učinkovitosti, a drugi na postupku nelinearnog programiranja učinkovitosti izvan profitnog sektora. Prema istom izvoru, sve su češće procjene učinkovitosti u skupinama međusobno usporedivih jedinica, pa se tako uspoređuje učinkovitost između gradova, regija ili država jer samoocjenjivanje i upravljanje kvalitetom poslovanja ne daje realnu sliku učinkovitosti ako se rezultati ne mogu staviti u odnos s rezultatima koje postižu druge organizacije iz istoga okruženja. Mjera učinkovitosti se stoga mora referirati na određeni standard ili se radi objektivnosti rezultata mora staviti u odnos prema postignutim rezultatima iz prijašnjih razdoblja iste organizacije, odnosno s usporedivim programima i organizacijama (Marković i sur., 2008.). Brojna istraživanja učinkovitosti to i potvrđuju, tako je Charnes sa suradnicima (1989.) istraživao učinkovitost 28 gradova i Kini u razdoblju od 1983. do 1944. godine, Maudos sa suradnicima (2000.) proveo je istraživanje učinkovitosti 17 regija u Španjolskoj u vremenu duljem od 30

godina, Mastromarco i Woitek (2006.) istraživali su tehničku efikasnost 20 regija u Italiji u razdoblju od 25 godina kao i mnoga druga.

Iako se povijest mjerenja učinaka upravljanja javnom upravom može pratiti od početka dvadesetoga stoljeća, intenzivniji razvoj sofisticiranih alata i metoda za mjerenje uspješnosti lokalnih vlasti započinje 90-ih godina. Holzer (2009.) navodi da su počeci mjerenja bili povezani uz prilagodbu računovodstvenih i proračunskih postupaka u alate kojima je bilo moguće prezentirati građanima odgovorno ponašanje politike u cilju pridobivanja njihova povjerenja i naklonosti. Dakle pad povjerenja u političare i vlast, ranih devedesetih godina prošloga stoljeća, utjecao je na razvoj novih alata i metoda za mjerenje učinkovitosti javne uprave. Od tada su razvijene brojne sofisticirane metode i alati za mjerenje ostvarenih učinaka koji se koriste na strateškoj i operativnoj razini, a u ovome će radu biti obrađeni sljedeći:

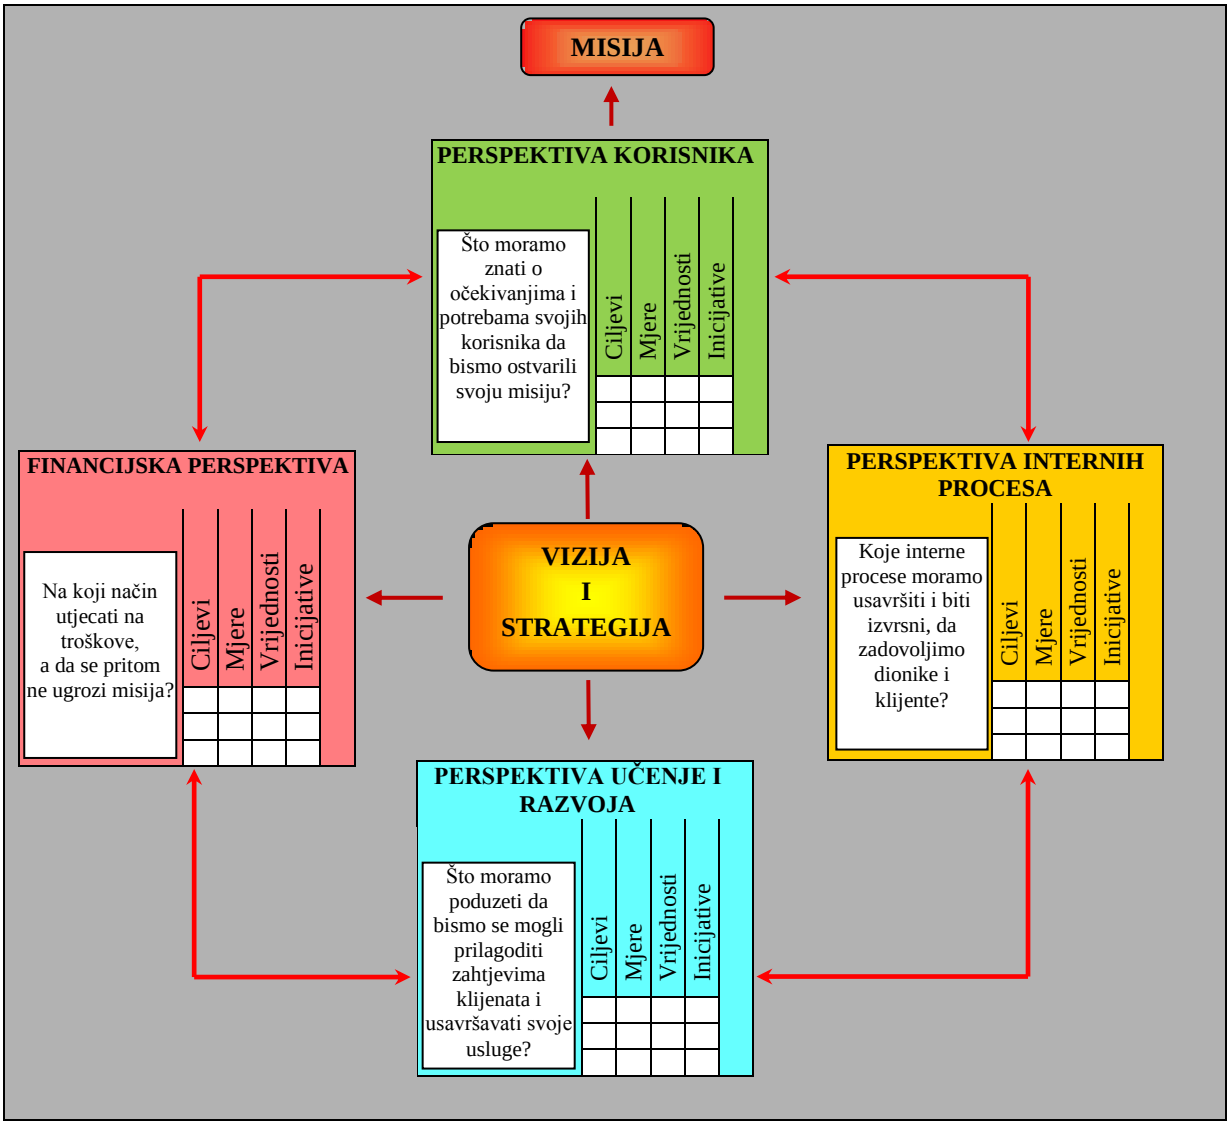
- model uravnoteženih ciljeva (eng. *Ballanced Scorecard – BSC*),
- europski model poslovne izvrsnosti (eng. *European Foundation for Quality Management - EFQM*) ,
- zajednički okvir za ocjenjivanje (eng. *Common Assessment Framework – CAF*)
- analiza omeđivanja podataka (eng. *Data Envelopment Analysis – DEA*).

3.1. Model uravnoteženih ciljeva - BSC

Vodeći se novim pristupima konkurentnosti u profitnom sektoru, prema kojemu su pokazatelji uspješnosti dobiveni financijskim mjerenjima postali neadekvatni za upravljanje i mjerenje učinkovitosti, javna je uprava 90-ih godina prošloga stoljeća prihvatila novi sustav upravljanja performansama, Balanced Scorecard. Novi je sustav zadržao financijske mjere, ali je dopunjen mjerama iz triju drugih perspektiva: kupaca-korisnika, internih procesa te učenja i rasta. Balanced Scorecard (BSC) se u hrvatskome jeziku prevodi na više načina, kao uravnotežena bodovna kartica, model uravnotežene kartice rezultata ili model uravnoteženih ciljeva, a uveden je 1992. godine od strane Roberta D. Kaplana i Davida P. Nortona u časopisu Harvard Business Review. Metoda BSC ima za cilj uspostavljanje uravnoteženog skupa mjera, koje menadžmentu osiguravaju informacije o ostvarenju ciljeva. BSC čini okvir za pretvaranje vizije i strategije poduzeća u operativne veličine i mjere, grupirane u četiri perspektive (*Slika 3-1*.), a to su:

1. financijski uspjeh,

2. odnos s klijentima,
3. interni procesi,
4. učenje i rast.



Slika 3-1: Model uravnoteženih ciljeva (Kaplan & Norton, 2000.)

Riječ *perspektiva* dolazi od latinske riječi *perspectus, gledati kroz nešto* ili *vidjeti jasnije*, a to je ono što odražava bit BSC-a; dakle ispitati strategiju čineći ju jasnijom kroz prizmu različitih gledišta (Niven, 2002.). U privatnom je sektoru najvažniji financijski aspekt koji u javnoj upravi i neprofitnom sektoru najčešće predstavlja ograničenje, a ne cilj (Kaplan i Norton, 2000.). Jer je menadžment u javnom sektoru usredotočen na programe i planove čija realizacija ovisi o proračunskim sredstvima.

Svaka perspektiva sadržava pokazatelje, od kojih se glavnina u javnoj upravi odnosi na nefinancijske. Prva je primjena modela BSC-a u javnom sektoru započela 1995. godine u gradu Charlotte, a danas se uspješno primjenjuje i u mnogim drugim gradovima (San Diego, Brisbane, Rijeka…). Kao što je ranije navedeno, profitni sektor je usmjeren na ostvarivanje dugoročnih strateških ciljeve s kojima moraju biti usklađene aktivnosti i kratkoročni ciljevi, dok je javna uprava usmjerena na ostvarivanje misije. Stoga se u organizacijama javnog sektora češće koriste indikatori ostvarenih učinaka nego indikatori ostvarenih rezultata (Kaplan, Norton, 2000.). Tako se i lokalna samouprava u definiranju svojih ciljeva usredotočuje na perspektivu zadovoljenja svojih klijenata uz ograničenje u financijskoj perspektivi iz jednostavnog razloga što klijenti s jedne strane predstavljaju korisnike javnih usluga, a s druge su strane izvor financiranja preko poreznih davanja. Stoga je gradovima financijska perspektiva (ograničeno) oruđe koje uvjetuje ostvarenje ciljeva u perspektivi klijenata, korisnika javnih usluga. U modelu BSC-a navedene četiri perspektive pokrivaju sva područja djelovanja određene organizacije, pri čem svaka od njih određuje koje su od njih značajnije s obzirom na viziju i strategiju. Ako određena jedinica lokalne samouprave ocijeni da je za njihovo poslovanje važno nešto drugo, što ne spada u četiri osnovne perspektive, moguće je u sustav uvesti nove perspektive iako Niven (2002.) napominje da se u kreiranju perspektiva za svoju organizaciju držimo zadanoga okvira s četiri perspektive.

Odnos s klijentima

U lokalnoj samoupravi ovo je najvažnija perspektiva koja proizlazi iz misije javne uprave - imati zadovoljne korisnike javnih usluga. Kod definiranja mjera za tu perspektivu jedinice lokalne samouprave moraju odrediti tko su klijenti kojima se nude usluge iz samoupravnog djelokruga, kako se odnositi prema javnim dionicima koji financiraju javne poslove i, na kraju, što svaka od navedenih skupina od njih očekuje. Prema Nivenu (2003.) svaka se jedinica treba svrstati u jednu od tri skupine koje se međusobno razlikuju prema strateškoj opredijeljenosti i to na:

1. *Operativnu izvrsnost* koju karakterizira pristupačnost uslugama, ali često bez dodatka vrijednosti,
2. *Proizvodno vodstvo* koje se odlikuje inovativnošću i izvrsnošću ponude,
3. *Prisnost s korisnicima* u kojoj lokalne vlasti nastoje zadovoljiti potrebe i zahtjeve svojih građana u cilju izgradnje dugoročnih veza.

Bez obzira na izbor, svaka jedinica lokalne samouprave mora razviti pokretače učinaka koji će dovesti do unaprjeđenja stanja u odnosu na prijašnja razdoblja. Osnovne pokazatelje uspješnosti u toj perspektivi nadopunjuju indikatori koji lokalnoj vlasti ukazuju na mjere i aktivnosti koje mora poduzimati da bi ispunila očekivanja i zahtjeve korisnika. Među njima je svakako povjerenje i imidž koje je lokalna vlast izgradila u prethodnom razdoblju.

Financijska perspektiva

Ciljevi i mjere u ovoj perspektivi ukazuju ispunjava li lokalna samouprava svoju misiju i vodi li provedba strategije, definirane mjerama u drugim perspektivama, do poboljšanja financijskih rezultata. Lokalna samouprava svoj rad temelji na ovoj perspektivi i o njoj ovisi svaka mjera i aktivnost iz drugih perspektiva, dok je ona u profitnome sektoru glavni cilj. Premda nam mjerenje financijskoga aspekta modela BSC-a daje informaciju o mogućnostima i opsegu pružanja usluga iz nadležnosti organizacije, s druge nam strane omogućuje uravnoteženje učinkovitosti i zavisnih troškova (Niven, 2003.).
Prema Kaplanu i Nortonu (2000.) u financijskoj perspektivi su sadržana strateška opredjeljenja koja u javnoj upravi odražavaju spremnost na kreiranje usluga više razine uz smanjenje troškova, drugim riječima učinkovitije korištenje raspoloživih resursa.
Ta je perspektiva u lokalnoj samoupravi okvir u kojem se planira ostvarenje ciljeva iz drugih perspektiva. Drugim riječima ova perspektiva u neprofitnim organizacijama predstavlja ograničenje i nije isključivo mjerilo razine dostignutih ciljeva iz strategije s obzirom na misiju javnoga sektora.

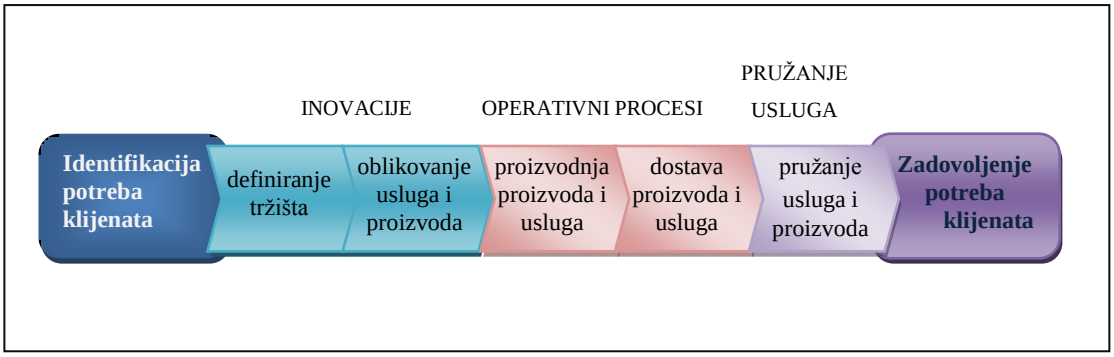
Interni procesi

Ova perspektiva obuhvaća mjere operativnih performansi (cijena, kvaliteta i vrijeme jednog ciklusa) i kritičnih procesa koji isporučuju vrijednost klijentima i utječu na smanjenje operativnih troškova. U toj perspektivi balanced scorecarda jedinica lokalne samouprave mora identificirati ciljeve i mjere za postizanje razine kvalitete usluga i proizvoda koja zadovoljava korisnike i javne dionike. Dobro organizirani interni procesi doprinose kvaliteti javnih usluga, skraćuju postupke, smanjuju troškove i pozitivno utječu na financijsku perspektivu, ukratko, povećavaju učinkovitost. U perspektivi unutarnjih procesa javna uprava mora iskazati visoku razinu inovativnosti i kontinuiranoga poboljšanja procesa, a definiranim ciljevima i mjere kojima se može pratiti i vrjednovati napredak. Kaplan i Norton (2000.) opisujući lanac vrijednosti internih procesa definiraju tri osnovne operativne razine (*Slika 3-2.*):

– proces inovacija,

– operativni procesi,

– proces pružanja usluga.



Slika 3-2: Perspektiva internih procesa – model osnovnog lanca (Kaplan & Norton, 2000.)

Svaka jedinica lokalne samouprave mora biti uspješna u ključnim procesima definiranih strategijom, koji u najvećoj mjeri doprinose stvaranju dodane vrijednosti za klijente i javne dionike. U praksi se često kroz tu perspektivu uvodi redizajn poslovnih procesa u nastojanju da se poboljšaju kritični indikatori učinkovitosti kao što su troškovi i kvaliteta usluga (Niven, 2003.). Izmjena internih procesa prati svaku mjeru usmjerenu povećanju učinkovitosti i najčešće je primjenjivana mjera u javnoj upravi, ali kao posljedica promjene politike upravljanja, a rjeđe kao strateško opredjeljenje.

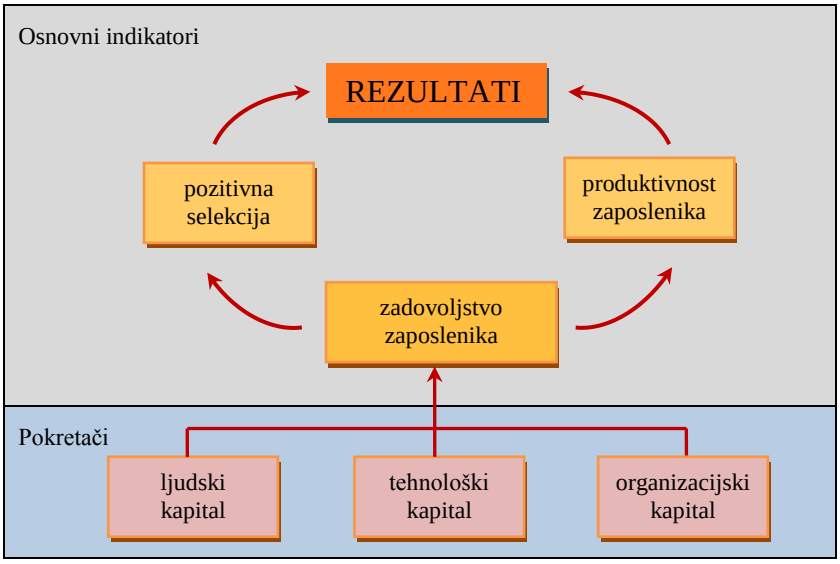
Učenje i rast

Perspektivom učenja i rasta svaka jedinica vrjednuje ljudske potencijale za pokretanje svih procesa i mjera koje su definirane u ostalim trima perspektivama, a osnovom su za izgradnju balanced scorecarda (Niven, 2003.). Ljudski su potencijali u javnoj upravi osnovna infrastruktura za ispunjenje ciljeva i mjera, a njome se izražava i upravljački potencijal političkoga menadžmenta. S obzirom na to da javna uprava pruža znatan otpor promjenama i prihvaćanju novih poslovnih procesa, to je ujedno i najosjetljivija perspektiva u kojoj je potrebno motivirati i potaknuti zaposlenike na aktivno uključivanje u ostvarivanje ciljeva i mjera. U ovoj mjeri organizacije mogu premostiti jaz između postojeće organizacijske infrastrukture, intelektualnog kapitala zaposlenika i okruženja u kojem se odvijaju procesi, ali s druge strane u ovoj se perspektivi može kriti i potencijalna opasnost za neuspjeh u provedbi mjera BSC-a. Niven (2003.) navodi da su u ovoj perspektivi ključne vještine i zadovoljstvo

zaposlenika, raspoloživost informacijama i usklađivanje, a mogu se definirati tri kategorije iz ove perspektive kojima se ostvaruje strategija:

1. Strateške kompetentnosti: vještine i znanje koji su potrebni zaposlenima kako bi mogli sudjelovati u realizaciji strateških ciljeva,
2. Strateške tehnologije: informacijski sustavi, baze podataka i tehnike potrebne za podršku strategiji,
3. Organizacijska klima: interne promjene koje će osigurati motivaciju i delegiranje autoriteta na zaposlenike kao glavne pretpostavke za uspješnu implementaciju strategije.

Dakle, napredak nije moguć bez osposobljenih i motiviranih zaposlenika, naprednih informacijskih sustava i okruženja za održavanje uspjeha. U pozitivnom međusobnom utjecaju ti elementi utječu na zadovoljstvo zaposlenika koji svojim učenjem i osobnim razvojem doprinose rastu organizacije. Uzročno posljedična veza tih elementa prikazana je na *Slici 3-3.* Menadžment koji nema povratnu informaciju o zadovoljstvu zaposlenika nema uvid u pravo stanje organizacije ni u drugim perspektivama i ne može na objektivan način definirati ciljeve i mjere za povećanje učinkovitosti. Zadovoljstvo zaposlenika omogućuje pozitivnu selekciju koja producira kompetentnost u obavljanju javnih poslova. U radnim sredinama gdje vlada nezadovoljstvo zaposlenika odlaskom ključnih i kompetentnih ljudi smanjuje se intelektualni kapital organizacije i financijski gubitak uloženih sredstava u njihov osobni razvoj i edukaciju.



Slika 3-3: Okvir za mjerenje učenja i rasta (Kaplan, Norton 2000.)

Stanje zadovoljstva zaposlenika u javnoj upravi ima izravan utjecaj i na korisnike usluga koji u kontaktu sa zaposlenicima stvaraju svoju sliku o organizaciji i razvijaju (ne)povjerenje u lokalnu vlast. Stoga je za različite vrijednosti i interne procese potrebno definirati odgovarajuću strategiju upravljanja znanjem koja podrazumijeva permanentno ulaganje u razvoj intelektualnog kapitala.

Dizajniranje BSC-a za svaku organizaciju ima cilj uspostavljanja ravnoteže u sustavu mjerenja performansi kroz nekoliko dimenzija i balansiranjem između kratkoročnih i dugoročnih pokazatelja uspješnosti, financijskih i nefinancijskih mjera performansi, kao i strategijskih i operativnih aspekata (Antić, 2005.).

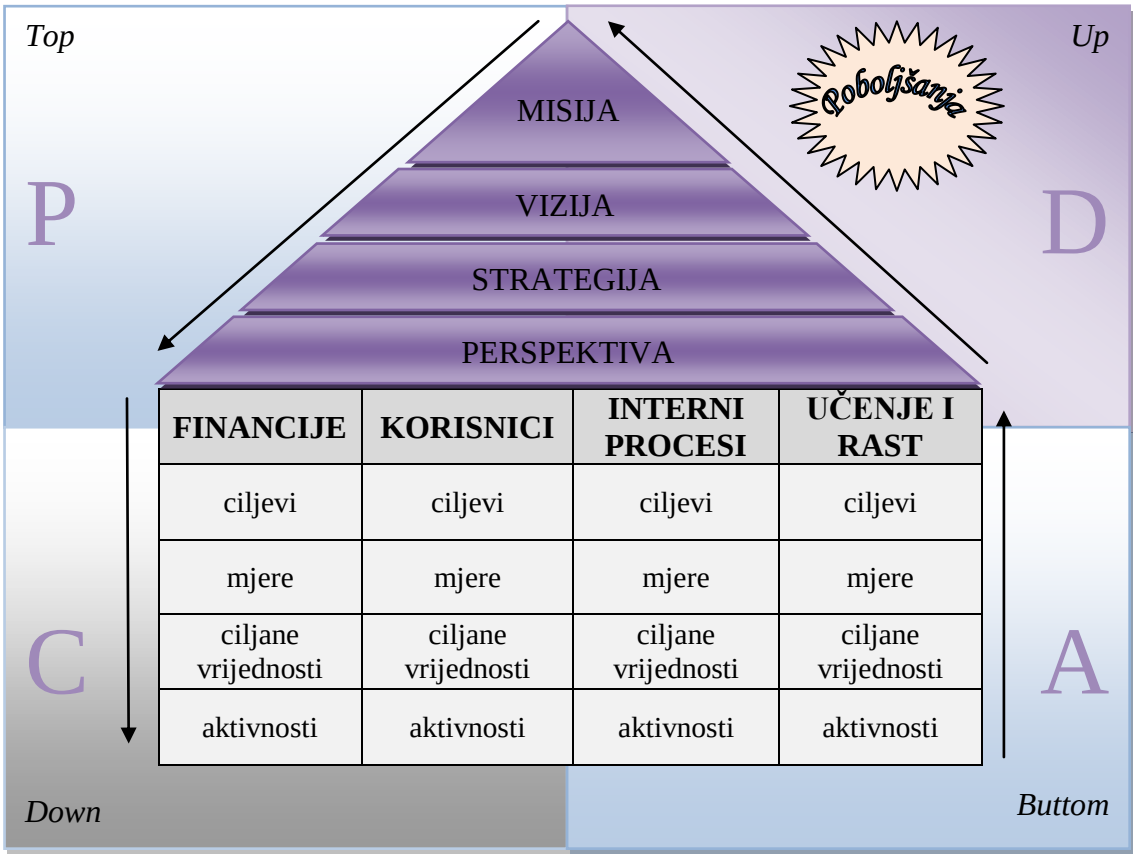
3.1.1. Faze izradbe BSC-a

U procesu izradbe sustava uravnoteženih ciljeva mogu se identificirati tri ključne faze kreiranja: misije, vizije i strategije. Misija je svrha i razlog postojanja organizacije i usko je povezana s njezinim budućim aktivnostima. Iz misije se izvodi vizija koja predstavlja željenu sliku organizacije u budućem razdoblju od 5 do 10 godina, čime ona predstavlja dugoročni cilj koji je postavljen pred organizaciju. Plan aktivnosti koje će biti provođene u cilju ostvarenja vizije jest strategija kao skup definiranih ciljeva koje treba postići i načina kako ih postići, a sve u cilju ostvarenja misije i kretanja prema definiranoj viziji. Dakle strategija je plan dugoročnog djelovanja koji omogućuje ostvarenje strategijskih ciljeva i pravilno usmjeravanje organizacije.

Postupak oblikovanja misije, vizije i strategije početna je faza primjene BSC-a koji povezuje viziju i strategiju sa svakodnevnim aktivnostima zaposlenika prevođenjem apstraktne strategije u jasne strateške prioritete i inicijative (*Slika 3-4*.).

Sve to povezuje strategiju s konačnim rezultatima kojima organizacija teži: zadovoljni korisnici, zadovoljni javni dionici, motivirani zaposlenici i učinkoviti procesi (Lončarević, 2006.). Dakle strategija se kao kontinuirani proces kaskadiranja transformira u skup akcija kojima individualni zaposlenici osiguravaju provedbu misije u svakodnevnome poslovanju. Sam sustav za upravljanje poslovanjem mora osigurati da se navedena tranzicija provede na efikasan način. Koraci za kreiranje BSC-a prema Kaplanu i Nortonu (2000.) naglašavaju potrebu da menadžment slijedi četiri osnovna načela:

1. Prevođenje strategije u operativne uvjete,
2. Usklađivanje organizacije sa strategijom
3. Prevođenje strategije u svakodnevne zadatke svih zaposlenika,
4. Učiniti strategiju trajnim procesom.



FINANCIJE	KORISNICI	INTERNI PROCESI	UČENJE I RAST
ciljevi	ciljevi	ciljevi	ciljevi
mjere	mjere	mjere	mjere
ciljane vrijednosti	ciljane vrijednosti	ciljane vrijednosti	ciljane vrijednosti
aktivnosti	aktivnosti	aktivnosti	aktivnosti

Slika 3-4: Prevođenje misija, vizije i strategije u BSC-u (Niven, 2003.)

Kao što je već navedeno, BSC je alat čija je osnovna uloga prevođenje misije, vizije i strategije organizacije u pregledan sustav za mjerenje učinaka što je na *Slici 3-4*. prikazano putanjom u smjeru *Top – Down*. Dakle strategija se mora pretočiti u jasno postavljene ciljeve u svakoj perspektivi da bi se na osnovi njih odredile mjere (pokazatelji), ciljane vrijednosti (granice) i, na kraju, aktivnosti koje se moraju poduzeti da bi se oni ostvarili.

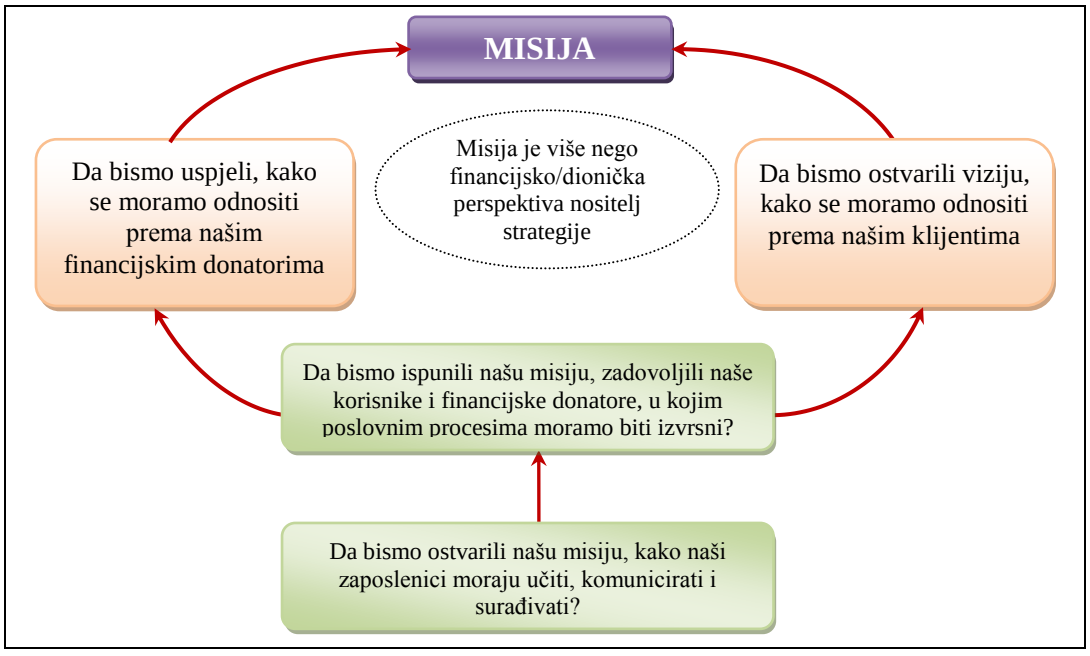
U putanji *Bottom – Up* se kroz aktivnosti usmjerene u cilju postizanja ciljanih vrijednosti i mjerenih pokazatelja vrjednuje stupanj realizacije zadanih ciljeva, što nas upućuje na učinkovitost organizacije u implementaciji strategije. Na taj se način permanentno odvija

ciklički proces PDCA[20] unutar organizacije u pravcu stalnih poboljšanja kroz sustav preispitivanja i poboljšanja strategije.

Da bi se cijeli proces transformacije vizije, misije i strategije što lakše predstavio provoditeljima na svim razinama, Kaplan i Norton (2001.) su razvili obrasce za izradbu strateških mapa kao alat kojim će organizacija iskomunicirati vlastitu strategiju, poslovne procese i sustave koji će poduprijeti provedbu te strategije. Ona daje zaposlenicima jasnu predodžbu koja je njihova svakodnevna uloga u postizanju ukupnoga cilja organizacije. To omogućuje koordinirano obavljanje poslova i nužnu suradnju na ostvarivanju zajedničkih ciljeva. Generalno gledajući, strateška mapa prikazuje na koji način tvrtka planira pretvoriti vlastite inicijative i resurse u konkretne rezultate.

Uspješan sustav BSC-a mora omogućiti ne samo uvid u postignute rezultate strategije i elemente koji su doprinijeli tomu rezultatu, već jednako tako mora identificirati i uzroke neuspjeha i omogućiti njihovo mjerenje i analizu.

Jedinice lokalne samouprave često nemaju jasno definiranu strategiju, već se BSC oslanja na misiju (*zašto postojimo?*) zbog usredotočenosti na učinkovitost u okviru raspoloživih resursa, (Pravdić, 2011.). Stoga se u kaskadiranju strateške mape polazi od vrha (misije) do perspektive korisnika (klijenata) za razliku od profitnoga sektora gdje se počinje od financijske perspektive i završava na dioničarima (*Slika 3-5.*).



Slika 3-5: Prilagodba Balanced Scorecard okvira neprofitnim organizacijama (Kaplan, 2001.)

[20] Plan – Do – Check – Act ; planiraj – učini – provjeri – djeluj (Prema W. E. Demingu)

3.1.2. Mogućnosti i ograničenja primjene BSC-a u lokalnoj samoupravi

Balaced scorecad sustav se nudi kao učinkovit alat koji omogućuje lokalnim vlastima strateško planiranje i upravljanje na osnovi pokazatelja uspješnosti koji se identificiraju kroz aktivnosti, ciljeve i mjere. Zbog multidimenzionalnoga pristupa, BSC se smatra i izvrsnim alatom za mjerenje učinkovitosti sustava unutar organizacija iz javnoga sektora (Umashev & Willett, 2008.). Znanstvenici koji su izučavali primjenu balanced scorecarda u neprofitnom sektoru ističu brojne prednosti i mogućnosti koje taj alat pruža korisnicima. Tako Kaplan (2001.) navodi da BSC u organizacijama javnog sektora pridonosi artikulaciji strategije na operativnu razinu i omogućuje da se:

- premosti jaz između misije, strategije i dnevnih operativnih aktivnosti,
- fokusira na strateška usmjerenja bez nepotrebnoga svaštarenja i lutanja,
- usredotoči na ostvarene rezultate programa i aktivnosti,
- izbjegne iluzija o posjedovanju dobre strategije na osnovi brojnih nepovezanih programa i inicijativa,
- uskladi djelovanje pojedinaca i odjela u cilju postizanja boljih učinaka.

U prilog primjeni sustava uravnoteženih ciljeva u lokalnoj samoupravi, kao organizaciji javnoga sektora, Niven (2003.) ističe sljedeće pogodnosti BSC-a:

- prikazuje odgovornost i generira rezultate,
- omogućuje učinkovito korištenje ograničenih resursa,
- naglašava strategiju,
- generira informacije umjesto podataka,
- omogućuje samoodržanje,
- vodi organizaciju prema promjenama,
- stvara povjerenje.

Analizirajući sustav BSC-a sa stanovišta upravljanja i menadžmenta, razvidne su brojne mogućnosti koje ga čine učinkovitim menadžerskim alatom za provedbu vizije i strategije, internu komunikaciju, definiranje i ostvarivanje ciljeva poslovanja i dobivanje povratnih informacija na osnovi kojih je moguće permanentno korigirati strategiju. Schwartz (2005.) navodi da BSC nudi menadžmentu brojne mogućnosti, a kao najznačajnije ističe:

- mogućnost usklađivanja strateških aktivnosti sa strateškim planom;
- identifikaciju najbolje prakse unutar organizacije i prenošenje istih na manje uspješne,

- dostupnost rezultata u realnome vremenu, što doprinosi donošenju brzih odluka važnih za kontrolu procesa u organizaciji,
- objektivno poticanje na osnovi stvarnih podataka, a ne na subjektivnim uvjerenjima pojedinaca,
- potiče osobnu odgovornost i angažiranost pojedinaca.

Uz navedeno, neki autori navode i suštinske kritike samog sustava koje se odnose na nemogućnost praćenja uzročno posljedičnih veza, što ograničava menadžment u aktivnostima koje je potrebno poduzeti nakon identificiranja izostanka postizanja zadanih ciljeva (Johanson i sur 2006.).

Međutim, BSC ima znatna ograničenja u odnosu na planirano istraživanje, poglavito na nemogućnosti vanjskoga vrjednovanja sustava u slučaju da organizacija ne posluje prema načelima BSC-a, nema jasno definiranu strategiju i nema međusobno usporedivo upravljanje procesima i ostvarenim učincima. Prema autoru ovoga rada samoocjenjivanjem i unutarnjim vrjednovanjem ograničen je benchmarking, a sama je organizacija usredotočena na vlastite uspjehe i nedostatke bez realnoga pozicioniranja u okruženju.

3.2. Europski model poslovne izvrsnosti (EFQM)

Europski model poslovne izvrsnosti (EFQM) jedan je od modela upravljanja kvalitetom u profitnom i neprofitnom sektoru koji definira izvrsnost kao rezultantu upravljanja resursima i procesima. Upravljanje kvalitetom podrazumijeva sustavno korištenje različitih metoda, tehnika i menadžerskih alata u cilju postizanja kvalitete procesa, proizvoda i usluga. Pojam se prvotno odnosio na kvalitetu proizvoda, ali se proširio na cjelokupnu organizaciju, odnosno ukupno poslovanje što i određuje izraz totalno upravljanje kvalitetom (eng. *Total Quality Management-TQM*). Potreba za upravljanjem kvalitetom javlja se u praksi sredinom prošloga stoljeća u Japanu koji je nastojao povećati tržišni udio u Europi i SAD-u povećanjem kvalitete proizvoda i usluga. U tome je nastojanju ustanovljena nagrada za izvrsnost, tzv. Demingova[21] nagrada, koja je prvi put dodijeljena 1951. godine i to poduzećima koja su se pokazala najboljima prema zadanim pokazateljima kvalitete poslovanja. Kao odgovor na tu nagradu,

[21] *William Edwards Deming* (1900. – 1993.) američki statističar, profesor, autor, predavač i konzultant. Demingova nagrada, koja je osnovana u prosincu 1950. u njegovu čast, izvorno je bila osmišljena za nagradu japanske kompanije za veliki napredak u poboljšanju kvalitete, no kasnije je proširena i na nejapanske tvrtke koje posluju u Japanu, kao i za pojedince koji su dali poseban doprinos unaprjeđenju kvalitete.

SAD je početkom šezdesetih godina prošloga stoljeća započeo postupak uvođenja sustava uspostavljanja nadzora nad kvalitetom u vojnoj i automobilskoj industriji. Osnova praćenja kvalitete bio je set upitnika koji su rukovoditelji proizvodnje bili dužni popunjavati. Osamdesetih godina prošloga stoljeća SAD su dopunile japanski model praćenja kvalitete TQM i prilagodile ga američkim uvjetima poslovanja na osnovi kojega je 1988. godine ustanovljena Malcolm-Baldridgeova[22] nagrada. Europa je u to vrijeme razvijala sustave standarda ISO 9000 što je kasnije utjecalo na razvoj brojnih standarda kvalitete. S druge strane, tražeći odgovore na sve izraženiju konkurenciju japanske i američke automobilske industrije na europskome tržištu, proizvođači automobila zapadne Europe ustanovili su *Europsku zakladu za upravljanje kvalitetom* (u daljnjem tekstu EFQM[23]). EFQM je neprofitna organizacija (zaklada) s više od 600 umreženih organizacija koje zajednički doprinose razvoju sustava ostvarivanjem željenih performansi. Tisuće organizacija diljem svijeta koriste načela EFQM-a kao vodiča za usklađivanje poslovnih strategija i poslovanja sa svojim misijama i ciljevima. EFQM je uz potporu Europske organizacije za kvalitetu (EOQ[24]) i Europske komisije razvio model poslovne izvrsnosti koji je i danas podlogom za dodjelu europske nagrade za kvalitetu (enlg. *European Quality Award*) koja objedinjuje nastojanja prije spomenutih nagrada u Japanu i SAD-u. Općenita je važnost ustanovljenih nagrada u poticanju pozitivne prakse i uspoređivanju s istim organizacijama u širem okruženju korištenjem benchmarkinga.

Osnovna načela izvrsnosti u modelu EFQM-a:

- *Usmjerenost na rezultate* polazi od činjenice da poslovna izvrsnost ovisi o uravnoteženosti u zadovoljavanju potreba svih zainteresiranih strana (dionika), što u javnome sektoru predstavljaju zaposlenici, korisnici/klijenti, gospodarstvo, država i društvo u cjelini.
- *Usmjerenost na klijente* pretpostavlja stavljanje klijenta/korisnika u središte pozornosti, kao subjekta koji daje konačnu ocjenu postignute izvrsnosti razinom zadovoljenja njegovih potreba i očekivanja.

[22] Engl. *Malcolm Baldridge National Quality Award* je godišnja nagrada koju dodjeljuje predsjednik SAD-a profitnim i neprofitnim organizacijama za izvrsnost.

[23] Engl. *European Foundation for Quality Management*

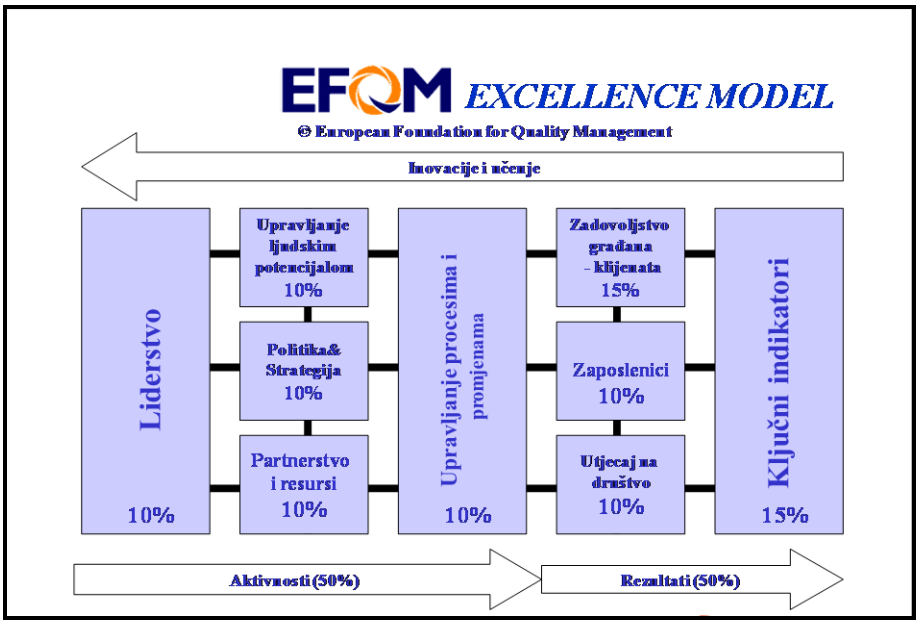
[24] Engl. *European Organization for Quality*

- *Vodstvo i postojanost svrhe* podrazumijeva dosljednost i jedinstvo u vođenju organizacije u skladu sa svrhom unutar organizacije i okruženjem u kojem organizacija i njegovi zaposlenici pokazuju svoju odlučnost.
- *Upravljanje pomoću procesa i činjenica* čini organizacije uspješnijima ako upravljaju sve međusobno povezane aktivnosti, a operativne poslovne odluke i planirana poboljšanja donose na osnovi pouzdanih podataka uključujući i mišljenja svih uključenih strana.
- *Razvoj i uključivanje zaposlenika* je povezano s načelom permanentnoga učenja i inoviranja jer se na taj način najbolje koristi ljudski potencijal razvijajući zajedničke vrijednosti i kulturu povjerenja motivirajući svakoga na puno uključivanje. Organizacija ostvaruje najbolje rezultate u okruženju kulture stalnoga *učenja i usavršavanja zaposlenika* što potiče njihovu inovativnost i kreativnost.
- *Razvoj partnerstva i društvene odgovornosti* su jednako tako međusobno povezana načela. Organizacija posluje uspješnije kada razvija dobre odnose s poslovnim partnerima zasnovane na međusobnom povjerenju, izmjeni znanja i integraciji. Jednako tako organizacija, zadovoljavajući dugoročne interese svojih zaposlenika i svih zainteresiranih strana (dionika) prema načelima društvene odgovornosti i etičnosti, zadovoljava opće društvene interese.

Prioriteti i međuovisnost osnovnih načela određeni su za svaki subjekt procjene zasebno, uvažavajući pri tom strateške ciljeve i misiju. Model ukazuje na to da postoji niz različitih načina kako bi se postigao cilj izvrsnosti, a on varira od organizacije do organizacije (Saraiva et al., 2001). Načelni EFQM model se sastoji od devet aspekata izvrsnosti od kojih pet opisuje aktivatore[25] organizacije za postizanje zadanih performansi, a četvero ukazuje na postignute rezultate (*Slika 3-6.*).

Dakle dva su pogleda - kako organizacija sustavno stvara preduvjete dobroga upravljanja (lijeva strana *Slike 3-6.*) te kakvi su postignuti rezultati (desna strana *Slike 3-6.*).

[25] Engl. *enablers*, što se u hrvatskoj literaturi prevodi kao aktivatori.



Slika 3-6: Europski model poslovne izvrsnosti (EFQM-a)

(www.efqm.org., prilagodio Bogović)

Mjerila europskog modela poslovne izvrsnosti

Na *Slici 3-6.* prikazano je 9 ključnih pokazatelja, koji obuhvaćaju 27 kriterija. Na osnovi njih moguće je izmjeriti dosegnutu razina upravljanja, ali i utvrditi koja su kritična mjesta poboljšanja u idućem razdoblju za postizanje izvrsnosti. Za svaki pokazatelj propisan je maksimalni mogući broj bodova koji se može dodijeliti u određenome području ocjenjivanja (kako u procesu samoocjenjivanja unutar organizacije tako i u procesu vanjskoga ocjenjivanja).

Ukupno je moguće ostvariti 1000 bodova (100%) određujući pri tome važnost određenog pokazatelja kroz veći ili manji broj maksimalno mogućih bodova, 50% na strani sposobnosti i 50% na strani rezultata (*Tablica 3-1*). EFQM fondacija je sastavila upitnik za svaki od devet ključnih pokazatelja na koji treba dati što preciznije i objektivnije odgovore.

Pomoću upitnika svaka organizacija može odrediti svoj položaj na skali izvrsnosti, otkriti potencijale za poboljšavanje i provoditi permanentno poboljšavanje. Upitnik se sastoji od uputa, 50 jednakovrijednih pitanja raspoređenih u devet aspekata prema modelu EFQM-a, modela bodovanja i obrasca za računanje postignuća u skupini aktivatora (eng. *enablers*), obrasca za računanje postignuća u skupini rezultata te model za računanje i grafičko prikazivanje profila organizacije.

Tablica 3-1: Značaj i vrjednovanja pokazatelja u EFQM modelu

<table>
<tr><th>AKTIVATORI
(Kako radimo stvari?)
500 BODOVA</th><th>REZULTATI
(Što postići - mjeriti,dostignuća?)
500 BODOVA</th></tr>
<tr><td>VODSTVO – LIDERSTVO (100 bodova)
– kako vođe (lideri) razvijaju i omogućuju provedbu misije i vizije, na koji način potiču vrijednosti za dugoročni uspjeh i provedbu istih putem odgovarajućih aktivnosti i ponašanja te kako su osobno uključeni u razvoj i uvođenje istog u sustav upravljanja</td><td rowspan="2">ZADOVOLJSTVO GRAĐANA – KORISNIKA
(150 bodova)
– na koji način organizacija zadovoljava očekivanja i potrebe svojih građana-korisnika javnih usluga</td></tr>
<tr><td>STRATEGIJA I RAZVOJNE POLITIKE (100 bodova)
– kako organizacija provodi svoju misiju i viziju putem jasno izražene strategije usmjerene zadovoljenju svih zainteresiranih strana, u kojoj mjeri su odražene u razvojnim politikama, planovima, ciljevima i procesima</td></tr>
<tr><td>UPRAVLJANJE LJUDSKIM POTENCIJALOM (100 bodova)
– kako organizacija upravlja, razvija i oslobađa znanja i koristi puni potencijal zaposlenika, koliko potiče timski rad i aktivnosti u cilju potpore svojim razvojnim politikama, strategiji i djelotvornosti radnih procesa</td><td>ZAPOSLENICI (100 bodova)
– koja razina zadovoljstva zaposlenika se postiže trenutno i što se može učiniti kako bi se odnos organizacije i zaposlenika unaprijedio</td></tr>
<tr><td>PERTNERSTVO I RESURSI (100 bodova)
– kako organizacija planira i rukovodi svojim vanjskim partnerstvima i internim resursima u cilju podržavanja razvojnih politika, strategije i procesa</td><td>DRUŠTVENA ODGOVORNOST
(100 bodova)
– na koji način organizacija doprinosi društvu u cjelini</td></tr>
<tr><td>UPRAVLJANJE PROCESIMA I PROMJENAMA (100 bodova)
– kako kreirati organizaciju, upravljati i unaprjeđivati poslovne procese, u cilju podupiranja razvojnih politika i strategije te u potpunosti zadovoljiti i generirati povećanje vrijednosti svojim klijentima i drugim zainteresiranim stranama</td><td>KLJUČNI INDIKATORI
(150 bodova)
– što organizacija ostvaruje u odnosu na planirane rezultate</td></tr>
</table>

Izvori:www.efqm.org i www.eknowledgcenter.com, prilagodio Bogović

Uloga upitnika u procesu samoocjenjivanja je više usmjerena na podizanje razine samosvijesti o uspješnosti organizacije, a manje na unaprjeđenje procesa u smislu efikasnosti (Gavrilović, 2007.). Na svako pitanje moguće je dati jednu od četiri moguće ocjene (prema opisu iz *Tablice 3-2*.) pri čem svaki član tima za ocjenjivanje mora pomno razmotriti objektivnost odgovarajućega pristupa ili modela i širinu njegove primjene u organizaciji. EFQM model je

1999. godine doživio prva poboljšanja[26] u smislu isticanja benchmarkinga, upravljanja znanjem, učenja i usavršavanja zaposlenika. Poboljšani je model više usmjeren korisnicima i upravljanju ljudskim potencijalima, a neka mjerila poput mjerenja poslovnog uspjeha (deveti aspekt – ključni indikatori) izravnava financijske indikatore (bilanca, financijski rezultat, financijski tijek itd.) s nefinancijskim indikatorima (ključni procesi, ukupna uspješnost, tehnološki potencijal, razvoj itd.).

Tablica 3-2: Tablica za procjenu kriterija prema EFQM-u

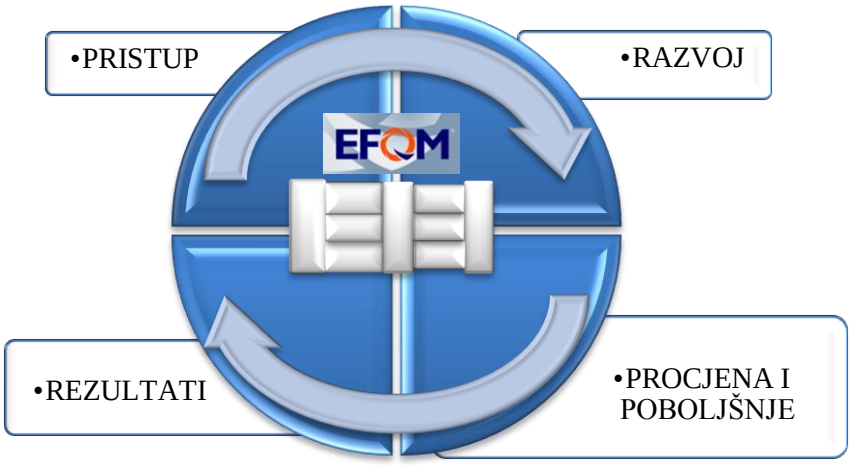
Rezultat	Bodovi	Stanje	Opis rezultata
D	**0**	Nije započelo	Uopće se mnogo toga ne događa, moguće su se pojavile neke dobre ideje, ali one nisu napredovale mnogo dalje od pozitivnoga razmišljanja (ništa konkretno i dokumentirano)
C	**33**	Mali napredak	Ima naznaka da se nešto zaista događa, povremena preispitivanja koja rezultiraju poboljšanjima i povećanjima, izolirana su područja uspješnih primjena i rezultata
B	**67**	Znatni napredak	Jasno vidljivo da je ovaj pristup dobro usvojen, redovita i rutinska preispitivanja i poboljšavanja, neke naznake da ostvarenje nije univerzalno ili primijenjeno punim potencijalom
A	**100**	Potpuno ostvareno	Izniman pristup ili rezultat primijenjen svugdje i s punim potencijalom, rješenje ili postignuće za uzor, teško je sagledati mogućnost za znatnije poboljšanje

Izvor: Oslić, I. 2009 „*Samoprocjena upitnikom EFQM*“ preuzeto na www.manager.hr

Novi model uvodi i novu metriku ocjenjivanja RADAR, što je kratica od **R**-Results (rezultati), **A**-Approach (pristup), **D**-Deployment (razvoj), **A**-Assesstment (ocjenjivanje) i **R**-Refine (poboljšanje) (*Slika 3-7.*). RADAR sustav samoocjenjivanja nastao je na osnovama Demingova sustava PDCA[27], a organizaciji služi kao alat za planiranje i procjenu poboljšanja.

[26] Introducinng excelence: Using the EFQM Excellence model to Improve Performance, 2004., str. 2.-3.

[27] Plan – Do – Check – Act ; planiraj – učini – provjeri – djeluj. (Prema W. E. Demingu)



Slika 3-7: RADAR model EFQM-a (www.efqm.org[28], prilagodio Bogović)

Samoprocjena se obavlja procjenjivanjem navedenih kriterija i podkriterija samopropitivanjem kroz RADAR matricu.

Rezultati (R) – Koje ciljeve nastojimo ostvariti da bismo ostvarili našu strategiju?

Pristup (A) – Kojim će pristupom organizacija ostvariti željene ciljeve? Kako ćemo pokušati ostvariti ciljeve u težnji približavanja poslovnoj izvrsnosti?

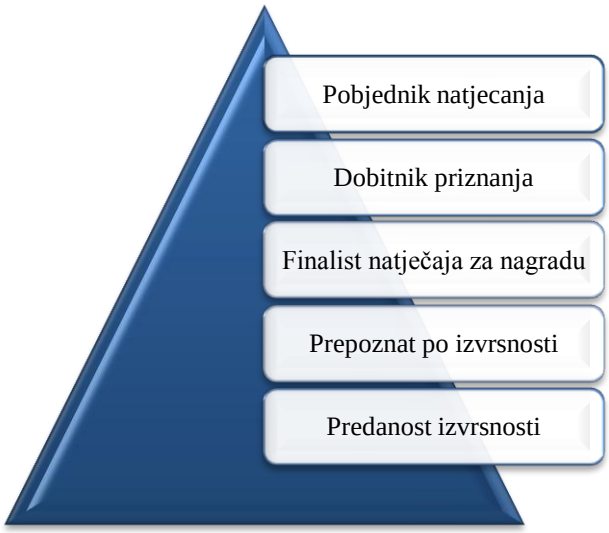
Razvoj (D) – Razvoj pristupa u provedbi aktivnosti i nastojanja za postizanje zadanih ciljeva. Čini li organizacija napore na razvoju svojih usluga (proizvoda) gdje god je to moguće?

Ocjenjivanje (A) i Poboljšanje (R) – Ocjenjivanje i kontinuirano unaprjeđivanje izabranoga pristupa na osnovi praćenja i analize postignutih rezultata. Kako mjerimo učinak mjera i kakva poboljšanja možemo još učiniti?

Veze između procesa i rezultata organizacije su relevantne pri ocjeni postignutih rezultata. Korištenjem EFQM modela, organizacija postavlja ciljeve i definira očekivane razine rezultata. Jednako tako ona usvaja strategiju, identificira i odabire odgovarajuće pristupe i operacije koje vode u koherentnu i dosljednu provedbu (implementaciju). Svaka organizacija koja je prihvatila sustav EFQM-a može procijeniti svoje poslovanje i kontinuirano poboljšanje procesa. Organizacije obično imaju nekoliko osnovnih procesa koji se moraju identificirati, opisati i operacionalizirati. Upravljanje procesima također uključuje i

[28] http://ww1.efqm.org/en/Home/aboutEFQM/Ourmodels/RADAR/tabid/171/Default.aspx

postavljanje ciljeva te odabir indikatora za mjerenje performansi procesa. Mjerenjem se može utvrditi učinkovitost pojedinih procesa ili nekoliko procesa vezanih uz rezultate organizacije. Poboljšanja modela ocjenjivanja modelom EFQM-a su 2002. godine omogućila uvođenje pet razina izvrsnosti EFQM-a (eng. *Levels of Excellence*) i piramide uspinjanja organizacije prema Europskoj nagradi za izvrsnost. (*Slika 3-8.).*



Slika 3-8: Razine izvrsnosti prema EFQM-u

Odlike organizacija prema navedenim razinama izvrsnosti:

- prvi stupanj *Predanost izvrsnosti* jest početak aktivnosti na uspostavljanju modela samoocjenjivanja, prijavljena organizacija mora objektivno – sagledavajući svoj trenutačni položaj – ispuniti dobiveni upitnik za samoocjenjivanje u svih devet aspekata izvrsnosti i odrediti potencijale za poboljšavanje,
- drugi stupanj *Prepoznat po izvrsnosti* uključuje organizacije iz prvoga stupnja koje su postigle razinu veću od 350 bodova, imaju čvrste pokazatelje poboljšavanja najvažnijih indikatora izvrsnosti EFQM-a u razdoblju od najmanje tri godine uključujući i rezultate iz branše,
- treći stupanj Finalist natječaja za Europsku nagradu za kvalitetu (EQA) podrazumijeva najmanje 450 bodova u sustavu samoocjenjivanja, organizacija ulazi u sustav monitoringa službenoga auditora EFQM-a, a za ulazak u višu razinu mora proći cijeli postupak kandidiranja za nagradu prema zahtjevu EFQM-a.

EFQM model je podložan stalnom inoviranju cijeneći pri tome iskustva korisnika u nastojanju da što uvjerljivije korespondira s mijenama u poslovnome okruženju koje nameću nove

prioritete i zahtijevaju stalnu prilagodbu. U osamnaestogodišnjem razdoblju nagrađeno je ukupno 261 organizacija iz 23 države, među kojima, dakako, nema Hrvatske.

Tablica 3-3: Prikaz dodijeljenih nagrada u razdoblju od 1992. do 2009. godine

Godina	1992.	1993.	1994.	1995.	1996.	1997.	1998.	1999.	2000.	2001.	2002.	2003.	2004.	2005.	2006.	2007.	2008.	2009.
Finalist	0	2	2	3	3	4	10	18	12	14	9	6	5	5	17	8	6	6
Dobitnik nagrade	3	1	2	1	3	4	7	5	8	5	6	9	9	9	6	5	2	7
Pobjednik natjecanja	1	1	1	1	1	2	3	4	3	2	1	4	2	2	4	4	3	0

Država	GB	ES	TR	DE	FR	HU	IT	DK	GR	NL	CH	BE	PL	IE	SK	UA	AT	SE	LU	RO	EE	PL
Udio (%)	19,9	15,9	10,8	10,4	6,4	5,6	4,4	3,6	3,6	3,2	3,2	3,2	1,6	1,6	1,2	1,2	1,2	1,2	0,4	0,4	0,4	0,4

Izvor: EFQM, Winners history[29]

Najveći broj nagrađenih organizacija bio je u Velikoj Britaniji (ukupno 50) i Španjolskoj (40), a prema popisu nagrađenih kroz proteklo razdoblje može se zaključiti da se i zemlje u razvoju uključuju u društvo razvijenih zemalja EU-a.

3.2.1. Mogućnosti i ograničenja primjene modela EFQM-a u lokalnoj samoupravi

Iako je EFQM model prilagođen i za javni sektor (javna uprava, zdravstvo, obrazovanje…), među nagrađenim organizacijama za sada nema ni jedne jedinice lokalne uprave. Ta činjenica ukazuje da ovaj model nije u potpunosti suživio s praksom upravljanja lokalnom samoupravom. Kako je postupak od prihvaćanja načela ocjenjivanja do kandidature za nagradu potrebno najmanje četiri godine, za očekivati je da će se u sljedećem razdoblju identificirati lideri kvalitete i u lokalnoj samoupravi. To u svakome slučaju ne možemo očekivati za gradove iz Republike Hrvatske, s obzirom na to da prema dostupnim informacijama ni jedan grad nije službeno prihvatio taj model, a prema službenim podatcima među liderima kvalitete nema ni jednoga poslovnog subjekta iz Hrvatske.

EFQM model izvrsnosti predstavlja najzahtjevniju koncepciju za razvoj menadžment sustava te ga je teško primijeniti bez odgovarajuće osnove. Bitna ograničenja u primjeni EFQM modela prema Raguž (2010.) mogu se svesti na sljedeće:

[29] http://ww1.efqm.org/en/Home/Ourservices/Recognition/tabid/128/Default.aspx (učitano 21. 02. 2010.)

- potreba za angažiranjem znatnih financijskih sredstava za implementaciju koncepata,
- proces implementacije je dugotrajan i iziskuje angažman velikoga broja resursa i promjene u organizacijskoj kulturi,
- povećane troškove treninga i edukacije zaposlenika,
- sporost dobivanja konkretnih mjerljivih rezultata,
- suparništvo i narušavanje timskoga rada,
- nedovoljno koncentriranje na ljudske resurse.

Osim navedenih ograničenja ovaj model u ocjeni učinkovitosti upravljanja ima znatna ograničenja, a kao najvažnija se mogu istaknuti sljedeća:

- uspješna implementacija zahtijeva aktivno sudjelovanje svih struktura unutar organizacije koja se vrjednuje, a poglavito onih na rukovodećim mjestima (gradonačelnik, pročelnici upravnih tijela…),
- potrebno je usuglasiti mjerila i metodiku na nacionalnoj razini da bi rezultati bili međusobno usporedivi i objektivni,
- u prve se dvije godine svaki sustav samoocjenjuje, a vanjsko je vrjednovanje moguće tek u trećoj godini, stoga EFQM nije pogodan alat za vanjsko vrjednovanje više međusobno usporedivih sustava, kao što su u slučaju ovoga rada veliki gradovi u Republici Hrvatskoj.

3.3. Zajednički okvir za ocjenjivanje - CAF

U lokalnoj samoupravi osim EFQM modela koristi se CAF (eng.-*Cammon Assesstment Framework*) koji se u hrvatskoj znanstvenoj literaturi prevodi kao zajednički okvir za ocjenjivanje. Taj je model izrađen na osnovama EFQM modela kao sredstvo organizacijskog samoocjenjivanja i utvrđivanja problematičnih aspekata javne uprave. CAF je razvijen suradnjom između ministarstva za javnu upravu zemalja članica Europske unije, Visoke škole za upravu iz Speyera[30], stručnjaka iz Europskog instituta za javnu upravu EIPA[31] i

[30] Speyer Hochschule für Vervaltungswissenschaften

[31] European Institute of Public Administration

eksperta za EFQM. Svake dvije godine održava se Europska konferencija za kvalitetu[32] na kojoj se razmatraju primjeri najbolje prakse i traže se poboljšanja u postojećem modelu. Za razvoj CAF modela bila je ključna konferencija u Lisabonu 2000. godine na kojoj je donesena odluka o pilot-projektu Zajedničkog okvira za ocjenu (*CAF*) u sedam različitih organizacija u trima državama Europske unije. S obzirom na pozitivna iskustva i postignute rezultate[33], broj korisnika od prve konferencije progresivno se povećavao; tako je prema podacima EIPA[34] 2002. godine model prihvatilo najviše organizacija javne uprave u Belgiji (više od 60) Italiji (oko 20) jednako tako i u Austriji, Njemačkoj Španjolskoj, Nizozemskoj, Danskoj, Finskoj, Švedskoj, Portugalu, Norveškoj i drugim državama Europske unije. Na konferenciji u Rimu 2003. godine naglašena je potreba usvajanja nacionalnih strategija za implementaciju CAF-a kao sredstva modernizacije uprave, te ključnu ulogu političke potpore za korištenje CAF-a. Danas se tim modelom koristi više od 900 organizacija javnoga sektora u više od 35 zemalja, a cilj je bio u 2010. godini imati 2.000 registriranih korisnika CAF-a. S jedne strane takvu ekspanzivnu primjenu CAF model zahvaljuje svojoj jednostavnosti primjene, dostupnosti i besplatnosti (Musa, 2008.) i, s druge strane, osnovnim karakteristikama sadržanima pod devizom „zajednički“ (eng. *common*) koje ga čine primjenjivim u javnom sektoru bez obzira na socioekonomsko i administrativno okruženje određenih zemalja. Taj su model prihvatile neke zemlje i prije ulaska u Europsku uniju; tako je Slovenija 2001. godine načelno prihvatila, a već 2002. godine započela pilot-projekt samoocjene osam organizacija iz područja javne uprave (Kovač, 2008). Još 2003. godine izrađena studija o korištenju CAF-a pokazala je da se u mnogim zemljama CAF preporučuje aktivnim djelovanjem centralnih institucija, a studija iz 2005. godine pokazala je da se u centralnoj državnoj upravi u Češkoj, Slovačkoj i Rumunjskoj CAF primjenjuje kao obvezan model, dok se preporučuje u drugih 15 zemalja EU-a. U većini zemalja koje koriste CAF model postoje nacionalne strategije za unaprjeđenje javne uprave, a zadatak koordinacije i promicanja modela izvrsnosti nose ovlaštena ministarstva ili državne agencije.

U Hrvatskoj CAF još nije službeno promoviran kao model u sklopu reforme i usklađivanja javne (lokalne) uprave sa standardima Europske unije jer ne postoji politički konsenzus o

[32] Do sada je bilo održano pet konferencija o kvaliteti: 2000. Lisabon, 2002. Kopenhagen, 2004. Rotterdam, 2006. Tampereu i 2008. Pariz te 2010. godine u Viliniusu.

[33] Zadovoljstva korisnika CAF modela veće je od 90%, prema *CAF works- better service for the citizens by using CAF*, 2007.

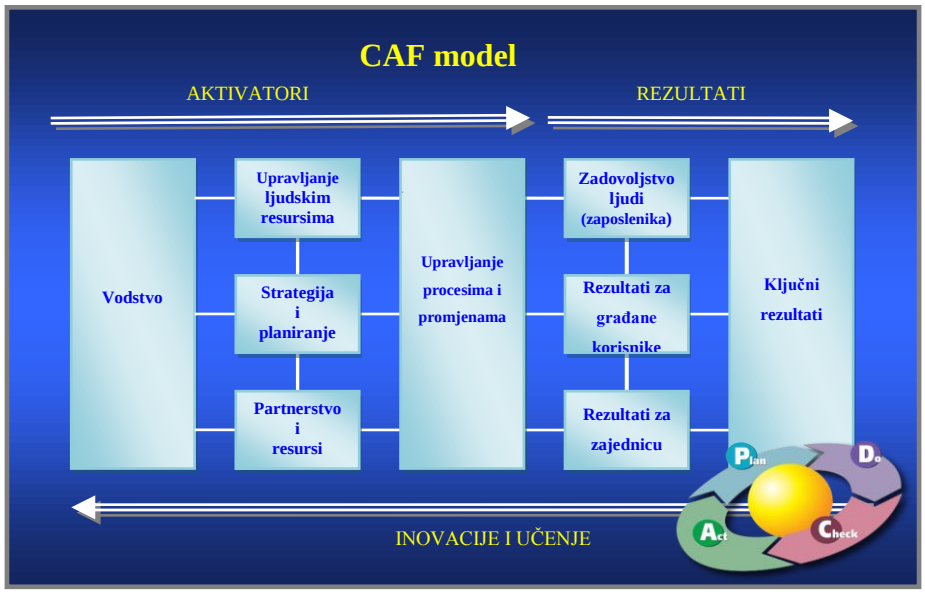
[34] www.eupan.eu

potrebi uvođenja nacionalnog sustava za praćenje i vrjednovanje rada javne uprave. No za očekivati je da se, povedeni pozitivnim iskustvima iz okruženja, i u našoj zemlji uskoro prihvati jedan od modela za ocjenu učinkovitosti i praćenje kvalitete u lokalnoj samoupravi.

Osnove Zajedničkoga okvira za ocjenu organizacija u javnome sektoru

Prema Steasu i Thijsu (2005., a) CAF model je shema organizacije koja predstavlja sve nužne aspekte za pravilno upravljanje organizacijom u cilju postizanja zadovoljavajućih rezultata. Svi su ključni elementi prevedeni u devet kriterija i operacionalizirani kroz 27 sub-kriterija na osnovi kojih se obavlja samoocjena. Sastav kriterija (*Slika 3-9*) jasno ukazuje na to da je razvijen na platformi EFQM modela, ali za razliku od EFQM modela kriteriji nisu ponderirani.

Slika 3-9: Zajednički okvir za ocjenu organizacija u javnome sektoru



Izvor: EIPASCOPE, http://aei.pitt.edu

Područja koja CAF analizira su sljedeća: vodstvo, strategija i planiranje, upravljanje ljudskim potencijalima, partnerstvo i resursi, upravljanje procesima i reformom, te četiri aspekta rezultata: orijentacija na korisnike, odnosno građane, ljudi, društveni rezultati te ključni rezultati izvedbe. Sustav bodovanja razrađen je tako da se mogu identificirati slabe točke u organizaciji kao i one u kojima je organizacija osobito uspješna, a koje mogu poslužiti kao osnova za širenje dobre prakse. Na osnovi dobivenih bodova izrađuje se akcijski plan za poboljšanje funkcioniranja organizacije. Korisnici CAF-a okupljaju se na CAF-ovim Korisničkim danima (CAF Users Events) na kojima razmjenjuju dobru praksu te iskustva u unaprjeđenju organizacija.

Istraživanja su pokazala (Staes i Thijs, 2005.b; EIPA, 2005) da su neki od razloga primjene CAF-a identifikacija jakih i slabih točaka u organizaciji, „skeniranje“ organizacije i stvaranje polazne točke za programe reorganizacije i poboljšanja, sudjelovanje na konferencijama za kvalitetu, jačanje svijesti o važnosti kvalitete, ali i pritisak od strane višega menadžmenta. Također, kao konkretna poboljšanja zbog primjene CAF-a ispitanici navode doprinos strateškom planiranju organizacije, stvaranje cjelovitog akcijskog plana, primjenu istraživanja na zaposlene, poboljšanje radnog procesa, kvalitete vodstva, menadžmenta znanja i financijskog menadžmenta, bolje upravljanje imovinom organizacije i sl.

CAF je besplatan, jednostavan i lako upotrebljiv mjerni instrument kojim se ocjenjuje učinkovitost i uspješnost organizacije, a koji je konstruiran u obliku upitnika. Njegova bitna karakteristika je samoocjenjivanje koje doprinosi izgradnji specifične organizacijske kulture jer u njemu sudjeluju sve skupine zaposlenih u organizaciji, što povoljno utječe na stupanj informiranosti i komuniciranja. CAF se može koristiti u svim vrstama organizacija (od organizacija državne uprave, regionalne i lokalne samouprave, javnih službi gospodarskog i negospodarskog karaktera; velike i male organizacije; dijelova organizacija ili velikih sustava) te u svakome kontekstu – kao dio opće reforme ili kao osnova za ciljano poboljšanje uprave ili pojedine organizacije. Prema Staesu i Thijsu (2005., a) specifičnosti CAF modela u odnosu na EFQM model mogu se sažeti na sljedeći način:

- uzete su u obzir specifične značajke organizacija javnog sektora,
- služi kao sredstvo za poboljšanje djelovanja organizacije,
- povezuje razne modele koji se koriste u okviru menadžmenta kvalitete,
- olakšava benchmarking organizacija javnoga sektora.

Ključna je prednost toga modela stalno uspoređivanje s najboljima (u području prakse i dostignuća) u cilju implementacije najboljih rješenja u svojoj organizaciji. Organizacije koje su implementirale taj model više sebe ne promatraju kao „crnu kutiju“ u kojoj promjene nisu moguće već postaju svjesne svojih dobrih i loših strana. Takva saznanja doprinose uvođenju promjena koje rezultiraju pozitivnim rezultatima za sve sudionike i javne dionike.

CAF ima četiri svrhe:

- da utvrdi specifične karakteristike svake uprave,
- da posluži kao koristan alat onima koji nastoje poboljšati performanse svoje organizacije,

- da služi kao kohezivni faktor među različitim modelima u upravljanju kvalitetom,
- da promiče benchmarking između lokalnih (samo)uprava, odnosno organizacija javnog sektora.

Zagovornici CAF-a tvrde da on pruža:

- evaluaciju zasnovanu na iskustvu,
- sredstvo kojim se postiže konzistentnost pravca kojim se treba ići i konsenzus o potrebama koje se trebaju zadovoljiti da bi došlo do poboljšanja,
- evaluaciju prema nizu kriterija koji su naširoko prihvaćeni u Europi,
- sredstvo mjerenja progresa tijekom vremena kroz periodične samoprocjene,
- vezu između ciljeva i strategija i procesa kojim se oni ostvaruju,
- sredstvo kojim se fokusira na aktivnosti unaprjeđenja koje su najnužnije u upravi,
- priliku za promicanje i međusobnu razmjenu dobrih praksi, kako unutar same uprave tako i između različitih uprava,
- sredstvo kojim se kreira entuzijazam među samim zaposlenima uključujući ih u procese uvođenja unaprjeđenja,
- prilike za identifikaciju napretka i razina dostignuća,
- sredstvo kojim se integriraju različite inicijative po pitanju kvaliteta u redovne aktivnosti.

Izrada i primjena CAF-a predstavlja jasan primjer kako upravna suradnja na različitim razinama dovodi do konvergencije djelovanja u javnoj upravi te, pretpostavljamo, i boljih rezultata. Polet (2006.) ističe da je razmjena najbolje prakse putem CAF-a dovela do jačanja suradnje između nacionalnih javnih uprava te nacionalnih javnih uprava i Europske komisije, između javnoga i privatnoga sektora u razvoju modela te, ne manje važno, između praktičara i znanstvene zajednice. U tom smislu upravna suradnja i širenje najbolje prakse putem razmjene ideja i iskustava korisnika CAF-a jest primjer difuzije ideja i tzv. *benchlearninga*.

3.3.1. Samoocjenjivanje CAF modelom u lokalnoj samoupravi

Iako se smatra da ne postoji univerzalan i jednako uspješno primjenjiv model ocjene izvrsnosti na sve lokalne samouprave, ovaj je model, zahvaljujući širokom opsegu analitičkih i međusobno primjenjivih mehanizama, prilagodljiv svim organizacijama javne uprave. CAF model je u javnoj upravi prihvaćen kao jednostavan alat za ocjenu koji je prema navedenim kriterijima i subkriterijima prilagođen za samoocjenjivanje prema navedenim pitanjima i

ljestvicama s ocjenama. Svaka organizacija u javnome sektoru, pa tako i gradovi kao velike jedinice lokalne samouprave, s osnovnim znanjem menadžerske prakse mogu se samostalno i uspješno koristiti CAF modelom. Uz prilagođenu metodiku i analitičke alate razvijene na pojednostavnjenoj platformi sustava kvalitete u profitnom sektoru koristi se lako razumljivim vokabularom (Engel, 2002.) za koji nisu potrebna specifična znanja. Prednosti samoocjenjivanja proizlaze iz načela da organizaciju najbolje poznaju oni koji u njoj rade ili njome upravljaju, ali to znanje rijetko samoinicijativno koriste da bi poboljšali rad i postigli više ciljeve. U tome smislu samoocjenjivanje ima ulogu izgradnje organizacijske kulture sa svrhom iskorištenja maksimalnih kadrovskih i materijalnih potencijala. Uz navedeno, samoocjenjivanje potiče internu komunikaciju, učenje i usavršavanje zaposlenih, potiče kompetitivnost zaposlenih i time ih motivira i involvira u usklađivanje osobnih s općim ciljevima. Kad se jedinica lokalne samouprave odluči na uvođenje CAF modela, osnovna je pretpostavka za uspješnu implementaciju dvosmjerna komunikacija na svim razinama organizacije, što podrazumijeva i aktivne rasprave u svim fazama uvođenja. Problem za upravljanje sustavima kvalitete u lokalnoj samoupravi je kako pridobiti sve zaposlene za provedbu CAF modela, kad su već svjedočili nizu neuspjelih pokušaja inoviranja uprave (ovisno o sklonosti vlasti prema menadžmentu promjena) iz čega proizlaze predrasude da je riječ o "još jednoj" inicijativi koja treba izliječiti sve probleme (Georg, 2003.). Upravo radi navedenog otpora zaposlenih i neangažiranosti političkoga menadžmenta u vođenju promjena, netransparentnosti, neuključenosti i neinformiranosti zaposlenika uvođenje CAF upravljanja lokalnom samoupravom je unaprijed osuđeno na neuspjeh. Iako samoocjena prema CAF-u ima niz pozitivnosti, jednako kao dva prethodna modela za poboljšanje kvalitete upravljanja, moraju biti dio strategije gradskih vlasti i moraju odražavati jasno opredjeljenje vlasti za poboljšanje rada uprave i objektiviziranje rezultata u odnosu na druge jedinice (benchmarking).

CAF s "pravim" samoocjenjivanjem omogućuje i osigurava[35]:

- ocjenjivanje na osnovi argumentiranih pokazatelja,
- postizanje konzistentne usmjerenosti i suglasja u svezi s tim što je potrebno učiniti za poboljšanje organizacije,
- ocjenjivanje prema zadanim kriterijima i mjerilima koja su prihvaćena u EU,

[35] www.eipa.eu/files/repository/product/CAFworks_EN.pdf

- periodičkim mjerenjima omogućuje praćenje napretka i usredotočenost postupaka poboljšanja na one ključne pretpostavke uspjeha koje su identificirane kao najslabije te mogućnost prepoznavanja napretka i uspjeha,
- povezivanje strategije s ciljevima i procesima,
- benchmarking među upravama s istoga područja djelovanja i izvan njega,
- pozitivna konkurentnost među zaposlenima, nastala njihovim aktivnim uključivanjem u procese poboljšavanja,
- mogućnost ugradnje drugih sustava kvalitete u običajno poslovanje.

Istraživanja Staesa i Thijsa (2005.b) pokazala su da lokalne vlasti primjenom CAF-a identificiraju svoje dobre i loše točke, a skeniranjem stvaraju preduvjete za reorganizaciju i poboljšanje. Jačanje svijesti o važnosti kvalitete jedan je od dugoročnih ciljeva. Ispitanici u lokalnim zajednicama su u navedenome istraživanju istaknuli doprinos CAF-a strateškomu planiranju, stvaranju cjelovita akcijskog plana, primjeni istraživanja na zaposlene, poboljšanje kvalitete upravljanja, promicanje znanja kao kvalitete, bolje upravljanje imovinom i dr. Iako se taj sustav kvalitete javne uprave ne primjenjuje u lokalnoj samoupravi u Republici Hrvatskoj, prihvaćanje nacionalne metodologije zasnovane na CAF modelu od strane lokalnih vlasti pretpostavlja organizacijsku prilagodbu. Premda CAF metodologija stavlja naglasak na stalno uspoređivanje s najboljima odnosno benchmarking u cilju implementacije najboljih rješenja u svojoj organizaciji, osamljeni slučajevi prihvaćanja metodologije samoprocjene ne mogu ispuniti svoju svrhu. U Hrvatskoj je prenaglašeno političko suparništvo na štetu benchmarkinga koji uključuje učenje, razmjenu informacija i usvajanje najbolje prakse, odnosno „učenje od boljih“ razmjenom iskustva s drugim sličnim organizacijama u javnom sektoru.

Prihvaćanje jednoga od postojećih modela za praćenje kvalitete u javnoj upravi (EFQM, odnosno CAF) može biti obrazac za pozitivne promjene ako se ono uvede kao nacionalni okvir i standardizira postupak prema nacionalnom obrascu za ujednačavanje kriterija kvalitete javne uprave i benchmarking. Povećanje kvalitete u hrvatskim gradovima može doprinijeti povećanju upravnog kapaciteta i racionalnijemu korištenju postojećih resursa, što će rezultirati i povećanjem učinkovitosti lokalnih vlasti. No još uvijek ne nudi odgovore na pitanja javnih dionika kako ocjenjivati i nadzirati kvalitetu lokalnih vlasti (vanjsko vrjednovanje), a ujedno omogućiti političkom menadžmentu da koristeći se istim alatom dobije jasne i sugestivne informacije o vlastitim nedostacima i mogućim poboljšanjima. Dakle

sustavi menadžmenta kvalitete mogu pozitivno utjecati na upravljanje javnom upravom, ali ne predstavljaju dovoljno operabilan menadžerski alat u ovakvom neuređenom okruženju kakvo je u Hrvatskoj.

3.4. Analiza omeđivanja podataka - AOMP

Među navedenim je nedostacima i ograničenjima prije navedenih modela, a ključno za ovaj rad, nemogućnost vanjskoga vrjednovanja na osnovi javno poznatih pokazatelja, što se često nameće kao potreba i to poglavito u javnome sektoru. Uz to mjerenju učinkovitosti u organizacijama koje nemaju jasno izražene poslovne procese transformiranja ulaza u izlaze, čiji su pokazatelji po prirodi raznorodni (financijski, gospodarski, socioekonomski...) i izražavaju se različitim mjernim jedinicama nije moguće primijeniti klasične mjere efikasnosti. U sustavima koji imaju raznorodne pokazatelje, čiji su željeni trendovi često suprotni, npr. stopa nezaposlenosti i porezni prihodi kao što je to slučaj u istraživanju učinkovitosti upravljanja velikim gradovima u Republici Hrvatskoj, potrebno je istovremeno obuhvatiti više ulaza i izlaza.

Analiza omeđivanja podataka (eng. *Date Envelopment Analysis- DEA*) je posebno dizajnirana tehnika za mjerenje učinkovitosti kompleksnih jedinica u kojima nije jasno izraženo koji ulazi (resursi) i u kojoj mjeri sudjeluju u stvaranju određenog izlaza (učinka). DEA se u hrvatskoj literaturi prevodi kao metoda analize omeđivanja podataka (AOMP ili AOP) (Rabar, 2010.), a predstavlja tehniku neparametarskoga linearnog programiranja koja se koristi za procjenu relativne učinkovitosti/efikasnosti jedinica za odlučivanje, odnosno donositelja odluka *DO* (eng. *Decision making units – DMU*) koje imaju iste ulaze i izlaze, a međusobno se razlikuju prema razini resursa kojima raspolažu i razini aktivnosti unutar procesa transformacije (Šporčić i ost., 2010.). Metoda AOMP-a se koristi u profitnome i neprofitnome sektoru posljednja tri desetljeća s tendencijom širenja primjene. Prema Emrouznejadu (2008.) do 2001. godine je obranjeno ukupno 196 doktorskih disertacija koje su u osnovi razmatranja imale primjenu analize omeđivanja podataka u mjerenju performansi.

Znanstvenu osnovu za mjerenje učinkovitosti predložio je Farrell 1957. godine koji je za mjerenje tehničke (proizvodne)[36] efikasnosti uzeo više ulaza koji sudjeluju u stvaranju jednog

[36] Tehnička odnosno proizvodna efikasnost je mjera efikasnog korištenja resursa u proizvodnji određene količine proizvoda.

izlaza i definirao granicu efikasnosti uzevši u obzir najbolju praksu iz skupa analiziranih jedinica. Nakon dvaju desetljeća (1978.) njegove su ideje proširili Charnes, Cooper i Rhodes koji su predstavili kvantitativni model za procjenu relativne efikasnosti jedinica DO-a u kojem je moguće obuhvatiti više ulaza i više izlaza pri čemu se u njihovom najpovoljnijem omjeru određuju ekstremne točke izlaza s obzirom na raspoložive ulaze (Cooper & Ray, 2008.). Tijekom godina, AOMP je postao važan operativni alat za analizu učinkovitosti u privatnome i javnome sektoru. Danas se AOMP primjenjuje u analizi učinkovitosti i uspješnosti u širokom rasponu analize produktivnosti i efikasnosti uspoređivanjem organizacija, tvrtki, regija i zemalja (Nikamp& Suzuki, 2009., Škuflić i ost. 2010.), a prema sistematiziranoj bibliografiji (Emrouznejad, 2008.) AOMP se primjenjuje u obrazovanju (škole i fakulteti), javnom zdravstvu, bankarstvu, vojsci, sportu, istraživanjima tržišta, poljoprivredi, trgovačkim društvima, transportu, stanogradnji i mnogim drugim područjima. Dakle, AOMP se uspješno koristi u privatnom i javnom sektoru.

Jednostavan primjer[37] analize osam organizacija s jednim ulazom i jednim izlazom će poslužiti za tumačenje osnova metode analize omeđivanja podataka (*Tablica 3-4).*

Tablica 3-4: Primjer AOMP s jednim ulazom i jednim izlazom

DO	A	B	C	D	E	F	G	H
ulaz (*zaposlenici))*	2	3	3	4	5	5	6	8
izlaz (*prodaja*)	1	3	2	3	4	2	3	5

Izvor: Cooper, 2005.

Metodom linearnog programiranja izračunata je relativna efikasnost DO u odnosu na druge iz skupa analiziranih i svakom neefikasnom je ponuđen referentni partner (eng. *benchmarking)* (*Tablica 3-5*).

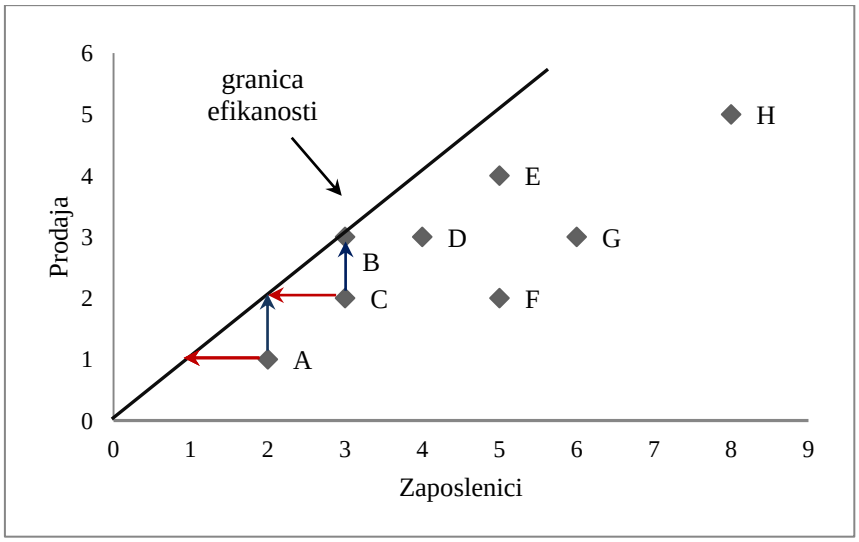
Tablica 3-5: Rezultat CCR efikasnosti

DO	A	B	C	D	E	F	G	H
Efikasnost *(CCR)*	0,500	1,000	0,667	0,750	0,800	0,400	0,500	0,625
Referentni DO	B	B	B	B	B	B	B	B

Izvor: Cooper, 2005.

[37] Primjer je preuzet iz Cooper, W., Seiford, L., Tone, K.: *Introduction to Data Envelopment Analysis and its Uses: With DEA-Slover Softver and References*, New York: Springer, 2005.

Samo je DO „B“ efikasan i kao takav je u referentnom skupu za sve preostale promatrane organizacije kao primjer dobre prakse. Prikaz na *Slici 3-10* je prikazuje geometrijski performanse u koordinatnom sustavu i granicu učinkovitosti koju u slučaju jednog ulaza i jednog izlaza predstavlja pravac koji polazi kroz ishodište kroz točku B.



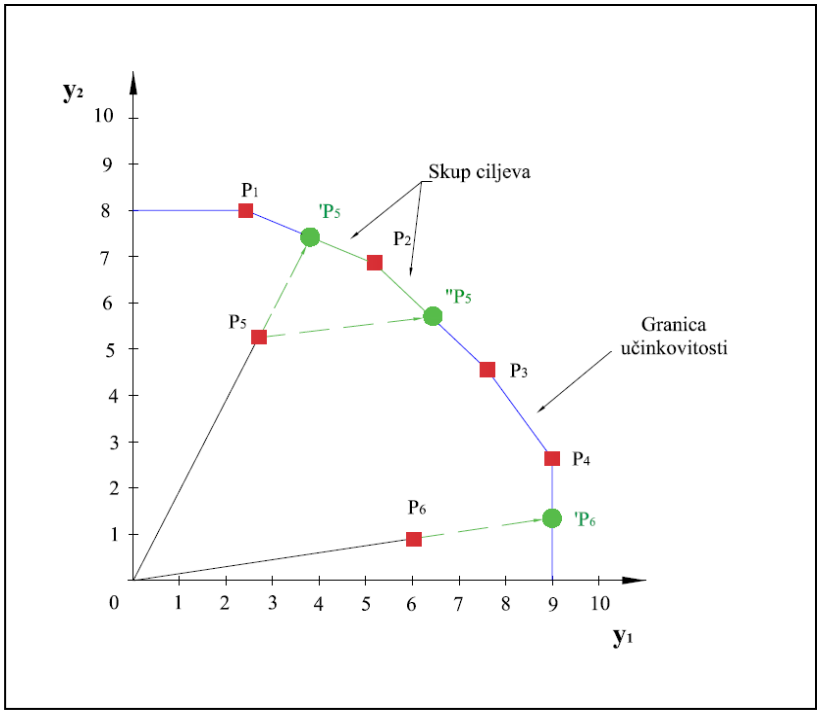
Slika 3-10: Grafički prikaz primjera AOMP

Vrijednosti relativne efikasnosti u *Tablici 3-5* pokazuju što mora poduzeti svaka jedinica za projekciju na granicu učinkovitosti. Na primjer relativna učinkovitost za entitet A=0,5 sugerira reduciranje ulaza na 1 (2x0,5=1) za ostvarivanje iste razine izlaza ili povećanje izlaza na 2 (1÷0,5=2) s istim ulazima. Jednako tako relativna efikasnost za C=0,667 sugerira smanjenje ulaza na 2 (3x0,667=2), odnosno povećanje izlaza na 3 (2÷0,667=3).

Dakle na osnovi podataka o ulazima i izlazima, AOMP metodom se ocjenjuje je li neka jedinica uspješna ili nije u odnosu na ostale jedinice koje su uključene u analizu. Ta je metoda razvijena za analizu relativne efikasnosti donositelja odluka (DO), konstrukcijom granice efikasnosti i projekcijom svakoga DO-a u odnosu na granicu.

Granica efikasnosti u ekonomskome smislu jest empirijski dobiven maksimum izlaza koji svaki DO može ostvariti s raspoloživim ulazima. Analizira se svaki DO i provjerava njegova mogućnost postizanja istih izlaza s manjom količinom ulaza, t.z.v. omeđivanja ulaza „odozdo“, imajući u vidu vrijednosti ulaza ostalih jedinica uključenih u analizu, kao i mogućnost postizanja boljih rezultata s istim ulazima ili omeđivanje izlaza „odozgo“ na osnovi vrijednosti rezultata ostalih jedinica.

Dakle AOMP je tehnika matematičkoga programiranja koja daje informaciju je li neki entitet, na osnovi podataka o njegovim ulazima i izlazima, efikasan ili nije, uspoređujući ga s drugim entitetima koji su obuhvaćeni analizom. Za razliku od parametarskih metoda koje procjenjuju performanse nekoga entiteta u odnosu na prosječne performanse, AOMP je metoda koja za svaku jedinicu uključenu u analizu izračunava njezine maksimalne mjere performansi u odnosu na druge dodjeljujući svakom pokazatelju optimalnu težinu. *Slika 3-11.* prikazuje analizu omeđivanja podataka u skupu od šest jedinica (P_1, P_2... P_6) koje djeluju u sličnim okolnostima, koristeći se istom količinom resursa za proizvodnju različitih količina učinaka (y_1 i y_2).



Slika 3-11: Granica efikasnosti prema BCC modelu[38]

Učinkovitije su one jedinice koje za određeni iznos ulaza (resursa) pružaju veći iznos izlaza (učinaka). Analiza omeđivanja podataka identificirala je jedinice P_1, P_2, P_3 i P_4 kao efikasne i one određuju granicu učinkovitosti ispod koje se nalaze jedinice P_5 i P_6 koje su neučinkovite. Za jedinicu P_5 primjeri dobre prakse su jedinice P_1 i P_2 koje ostvaruju veću količinu outputa, a skup ciljeva za P_5 nalazi se u točki 'P_5. Ti su ciljevi ostvarivi razmjernim povećanjem izlaza jedinice P_5, pri čem postoje i drugi alternativni ciljevi za P_5 ("P_5). Za jedinicu P_6 proporcionalno povećanje izlaza dovodi do ciljeva 'P_6, međutim P_4 unatoč tomu jasno

[38] Preuzeto na http://www.deazone.com/tutorial/graphical.htm

dominira jer ostvaruje istu razinu y_1, ali veću razinu y_2 izlaza. U tome slučaju povećanje izlaza mora biti dopunjeno proporcionalnim porastom izlaza y_2. U tome okviru moguće je procijeniti *ex post* (ne)učinkovitost određenoga entiteta pomoću njegove udaljenosti do empirijske granice učinkovitosti. Jedinice koje određuju granicu učinkovitosti su uspješne, a stupanj (ne)uspješnosti ostalih jedinica mjeri se na osnovi udaljenosti njihova ulaz/izlaz omjera (kontribucije) u odnosu na granicu uspješnosti (isprekidana linija na *Slici 3-11*). Dakle DO koji se nalazi na granici je učinkovit dok su svi ostali ispod granice neučinkoviti. Neučinkoviti DO svoju efikasnost postiže projekcijom na granicu efikasnosti, a nju može postići reduciranjem ulaza (resursa) ili povećanjem izlaza (rezultata). S obzirom na to da postoji velik broj mogućih poboljšanja u sferi ulaza i izlaza postoji i mnogo rješenja za pojedine neučinkovite DO kako bi se poboljšala učinkovitost.

Prema iznijetom AOMP može biti strateško i organizacijsko oruđe za razumijevanje funkcioniranja pojedinih jedinica lokalne samouprave koje u kontekstu *benchmarkinga* nudi manje uspješnim jedinicama učenje od uspješnih uz uočavanje vlastitih slabosti. Ta je metoda prema mišljenju mnogih znanstvenika pogodna za ocjenu uspješnosti upravljanja gradovima uzme li se u obzir da je gotovo nemoguće utvrditi potrebnu količinu resursa za postizanje određene razine ekonomski mjerljivih učinaka jer nije poznata eksplicitna ovisnost između utrošenih resursa i postignutih rezultata, a resursi koji sudjeluju u „proizvodnji“ određenoga pokazatelja uspješnosti lokalne samouprave su brojni i nisu strogo zadani.

3.4.1. Modeli AOMP-a

Prema Cooperu i suradnicima (2006.) primarni koncept mjerenja učinkovitosti donositelja odluka (DO) formaliziran je u obliku matematičkoga modela razlomljenog linearnog programiranja koji se može transformirati u linearno programiranje koje se može izraziti sljedećim matematičkim izrazom:

$$Max\ h_0 = \sum_{j=1}^{n} u_j\ y_{jk0} \tag{1}$$

kao i:

$$\sum_{i=1}^{m} v_i\ x_{ik0}\ = 1 \tag{2}$$

$$\sum_{j=1}^{n} w_j\ y_{jk0}\ \leq \sum_{i=1}^{m} v_i\ x_{ik0} \tag{3}$$

gdje je:

- k broj jedinica odlučivanja
- m broj ulaza (inputa)
- n broj izlaza (outputa)
- u težinski koeficijent izlaza
- v težinski koeficijent ulaza

Tijekom korištenja ovom metodom u proteklih trideset godina razvijen je veći broj modela (Cooper i ost., 2006.), a u ovom će radu biti prikazani samo osnovni koji se uobičajeno koriste u istraživanjima učinkovitosti (Rabar, 2011.): CCR i BCC modeli nazvani prema inicijalima svojih autora (CCR po Charnes Cooper Rhodes, a BCC po Banker Charner Cooperu). Osnovna se razlika između tih dvaju modela sastoji u pretpostavljenoj transformaciji inputa u outpute. S obzirom na karakteristike procesa u lokalnoj samoupravi, u analizi učinkovitosti upravljanja gadovima koristit će se oba modela čije će osnovne karakteristike biti opisane u nastavku.

3.4.1.1. Charnes Cooper Rhodesov model (CCR)

Ovaj je model vjerojatno najčešće korišteni i najpoznatiji DEA model koji je zasnovan na pretpostavci konstantnih prinosa, što znači da svaka izvedivost aktivnosti (xy) povlači izvedivost aktivnosti (x_t, y_t) za svaki pozitivan broj t. Model su prvi predstavili Charnes, Cooper i Rhodes 1978. godine u članku objavljenome u European Journal of Operational Research, vol. 2, br. 6, str. 429–444, te je stoga i nazvan prema njihovim inicijalima.

CCR model izračunava ukupnu učinkovitost za svaku jedinicu u koju je uključena čista tehnička učinkovitost i efikasnost kao učinkovitost ovisna o obimu poslovanja. pri čem se tehnička učinkovitost i mjerila učinkovitosti spajaju u jednu vrijednost. U modelu se za svaku jedinicu DO nastoji maksimalizirati h_k na način da se svakoj varijabli odabranih pokazatelja dodjeljuje težinski koeficijent koji joj najviše odgovara. Dodjelom najpovoljnijih težinskih koeficijenata svakoj varijabli dobivaju se virtualni ulazi i izlazi (Cooper i dr., 2006.)

$$\text{virtualni ulaz} = v_1 x_{10} + \cdots + v_m x_{m0}$$
$$\text{virtualni izlaz} = u_1 y_{10} + \cdots + u_n y_{n0}$$

Potrebno je pronaći nenegativne težinske koeficijente koristeći linearno programiranje tako da se maksimizira omjer virtualni output/virtualni input, uz ograničenja da njihov ne može biti veći od jedan za svakog promatranog DO. Autori Charns,Cooper i Rhodes su predložili model za optimizaciju svakog DO koji se može izraziti kao:

$$Max\ h_k = \sum_{j=1}^{n} \mu_j\, y_{jk} \Big/ \sum_{i=1}^{m} v_i\, x_{ik} \tag{4}$$

uz uvjet da:

$$\sum_{j=1}^{n} \mu_j\, y_{jk} \ \leq \ \sum_{i=1}^{m} v_i\ x_{ik} \tag{5}$$

odnosno:

$$\sum_{j=1}^{n} \mu_j\, y_{jk} \ \Big/ \sum_{i=1}^{m} v_i\ x_{ik} \ \leq 1 \tag{6}$$

pri čemu:

$$\mu_j \geq 0,\ j = 1,2, \ldots., n; \text{ kao i } \mu_j \geq \varepsilon \tag{7}$$

$$v_i \geq 0, \quad i = 1,2, \ldots., m; \text{ kao i } v_i \geq \varepsilon \tag{8}$$

gdje je:

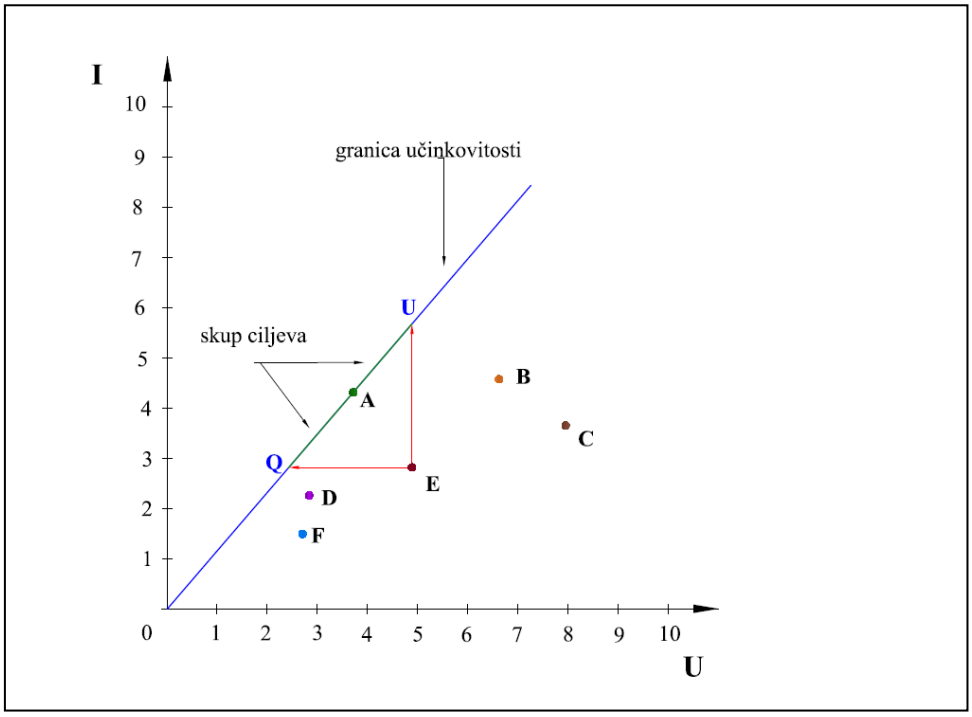
- h_k relativna učinkovitost *k*-te DO
- *k* broj jedinica odlučivanja
- *m* broj ulaza (*x*)
- *n* broj izlaza (*y*)
- *v* težinski koeficijenti ulaza *(x)*
- μ težinski koeficijenti izlaza *(y)*
- ε mala pozitivna vrijednost (najčešće $\varepsilon = 10^{-6}$)

Za *k*-ti DO se traži maksimizacija učinkovitosti (4-6) uz uvjet da je težinska suma izlaza manja od težinske sume ulaza (5) iz čega slijedi da je $0 < h_k \leq 1$. Ukoliko je funkcija $h_k = 1$ onda je *k*-ti DO relativno učinkovit, a ako je manja $h_k < 1$ onda je k-ti DO relativno neučinkovit, a sama vrijednost h_k pokazuje koliko je potrebno racionalizirati potrošnju resursa ili povećati rezultate da bi *k*-ti DO postao učinkovit.

Jedinica DO-a se može smatrati učinkovitom ako ni jedna druga jedinica iz *k* skupa s njenim optimalnim težinskim koeficijentima ne može ostvariti veću vrijednost izlaza za dati ulaz (Savić, 2009.) i takve jedinice definiraju granicu učinkovitosti. Drugim riječima učinkovitost svakog DO-a je maksimizirana odabirom optimalnih težinskih koeficijenata za svaku varijablu, a DO je učinkovit ako ne postoji ni jedan drugi DO iz promatranog skupa, koji sa svojim optimalnim težinskim koeficijentima i njegovim ulazima postiže bolje izlaze. Težinski koeficijenti prema ograničenjima sadržanim u izrazu (7) i (8) mogu imati samo

nenegativnu vrijednost, a vrijednost ε sprječava potpuno zanemarivanje varijable u izračunu relativne učinkovitosti.

Učinkovite jedinice DO definiraju granicu učinkovitosti koja se u CCR modelu zbog pretpostavke konstantnih prinosa prikazuje konveksnom linijom, a u primjeru s jednim ulazom i jednim izlazom u kojem granicu učinkovitosti definira DO „A“ označena je pravcem (*Slika 3-12)* koji ilustrira primjer analize učinkovitosti šest jedinica DO. Neučinkovite jedinice DO-a se nalaze ispod granice učinkovitosti, a njihova projekcija na granicu učinkovitosti se postiže smanjenjem ulaza (inputa) ili povećanjem izlaza (outputa). Za DO „E“ točka Q predstavlja projekciju na granicu učinkovitosti prema ulazno usmjerenom CCR modelu, a točka U prema izlazno usmjerenom CCR modelu (Rabar, 2010).



Slika 3-12: Prikaz granice efikasnosti prema CCR modelu (Rabar, 2010.)

Značajne promjene ulaza ili izlaza u praksi je teško ostvariti, stoga se traži kompromisno rješenje koje se nalazi na dužini između točke Q i U koja se postiže istovremenom racionalizacijom ulaza uz povećanje izlaza.

Ovaj model je ujedno najčešće korišten model u analizi efikasnosti (učinkovitosti), a dobiveni rezultati izražavaju ukupnu tehničku učinkovitost, a za čistu tehničku efikasnost koristi se BCC model.

3.4.1.2. Banker Charner Cooperov model (BCC)

U slučaju rastućeg ili opadajućeg prinosa, kada proporcionalna promjena varijable ulaza rezultira više ili manje proporcionalnim povećanjem izlaza, koristi se BCC model AOMP-a. Ime je dobio po Banker, Charnes i Cooperu koji su ga prvi predstavili u članku objavljenome u *Management Science* (1984, Vol. 30/9, str. 1078-1092). BCC modelom mjerimo čistu tehničku efikasnost, odnosno on daje mjeru efikasnosti koja zanemaruje utjecaj opsega poslovanja tako što se j-ta jedinica DO-a uspoređuje samo s jedinicama sličnoga opsega. On se može definirati sljedećim izrazom (YU-Chuan, 2010.):

$$(Max)h_k = \sum_{j=1}^{n} \mu_j \, y_{jk} + u_* \tag{9}$$

$$\sum_{i=1}^{m} v_i \, x_{ik} = 1 \tag{10}$$

$$\sum_{j=1}^{n} \mu_j \, y_{jk} - \sum_{i=1}^{m} v_i \, x_{ik} + u_* \leq 0, \qquad k = 1,2 \ldots, n \tag{11}$$

$$\mu_j \geq \epsilon, j = 1,2, \ldots, n \text{ i } v_i \geq \epsilon, i=1,2,\ldots,m \tag{12}$$

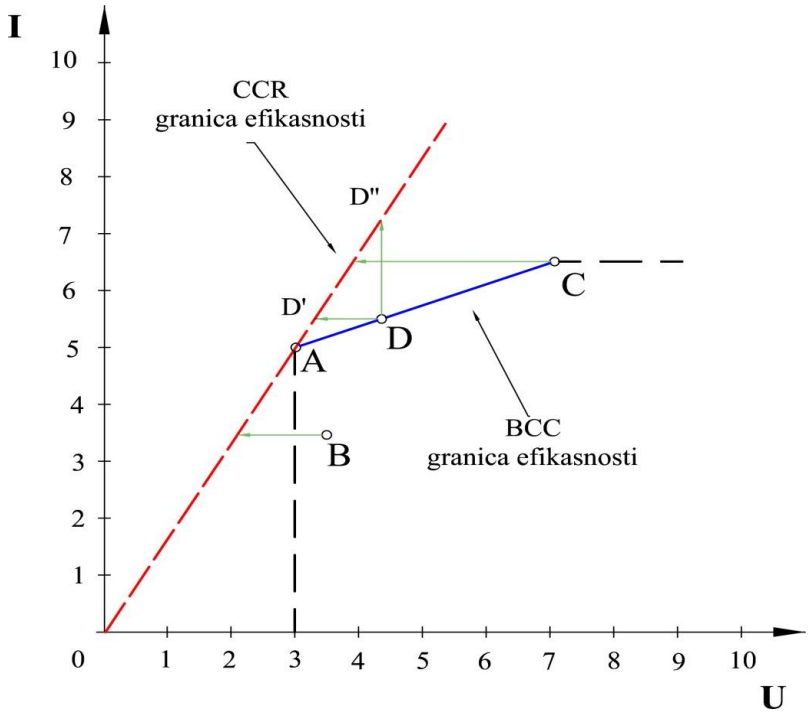
gdje je:

- h_k - rezultat učinkovitosti *k*-te jedinice DO-a,
- y_j predstavlja *j*-ti izlaz (*output*) *k*-tog DO,
- x_i je težinski koeficijent *i*-tog ulaza (*inputa*),
- μ_j je težinski koeficijent *j*-tog izlaza,
- n broj izlaza
- m broj ulaza
- u_* je dodatna varijabla koja definira utjecaj opsega poslovanja.

Dakle tim se modelom analizira učinkovitost jedinica koje ostvaruju varijabilni prinos u odnosu na opseg (eng. *Variabel return to scale – VRS*), a granica efikasnosti u ovome slučaju je konveksna krivulja. Prema Savić (2009.) za DO koji definiraju granicu učinkovitosti dodatna varijabla definira prirodu poslovanja na slijedeći način:

- ako je vrijednost $u_* = 0$ onda se BCC model svodi na CCR model, a DO_k posluje s konstantnim prinosom s obzirom na opseg poslovanja,
- ako je vrijednost $u_* \leq 0$ DO_k posluje s neopadajućim prinosom s obzirom na opseg poslovanja i
- ako je vrijednost $u_* \geq 0$ DO_k posluje s nerastućim prinosom s obzirom na opseg poslovanja.

U cilju lakšeg prikaza osnovnih razlika u interpretaciji učinkovitosti između tih dvaju osnovnih modela analize omeđivanja podataka, koristit će se jednostavan prikaz učinkovitosti pet jedinica s jednim ulazom i jednim izlazom prema *Slika 3-13.* Svaki DO je prikazan u koordinatnom sustavu kao jedna točka koju određuje vrijednost ulaza i izlaza, a prikazane su i granice efikasnosti prema CCR i BCC modelu. Učinkovitost prema CCR modelu definira linija koja prolazi od ishodišta kroz točku A.



Slika 3-13: Granica efikasnosti prema BCC i CCR modelu[39]

[39] Preuzeto na www.deazone.com

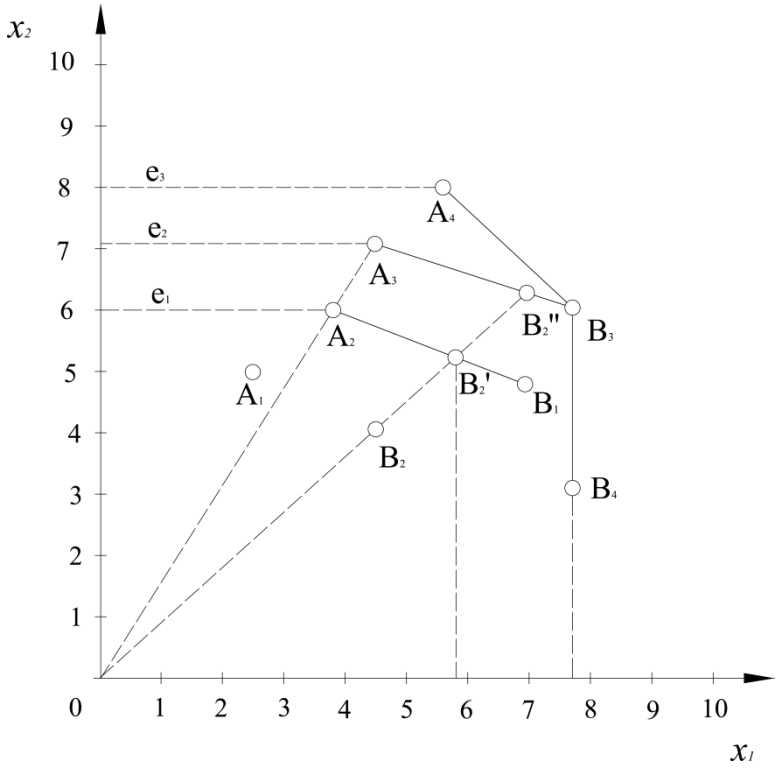
U slučaju kada se učinkovitost određuje na osnovi samo jednog izlaza i ulaza, granicu efikasnosti predstavlja pravac jer model predviđa konstantan prinos. Ako se analizira CCR učinkovitost jedinica A i D može se zaključiti da jedinica A ostvaruje za 1,7 veći izlaz u odnosu na ulaz, dok je za DO D taj odnos 1,3 : 1. To znači da je D neefikasna jedinica jer je njezin prinos na opseg manji od prinosa koji ostvaruje A. Ona bi mogla postati efikasna kada bi se projicirala na granicu učinkovitosti koju definira pravac 0A (između točaka D' i D''), odnosno smanjenjem ulaza ili povećanjem izlaza. Za razliku od CCR granice učinkovitosti, prema BCC modelu granicu učinkovitosti predstavlja linija koja spaja točke A i C. U ovom slučaju izračuna efikasnosti DO C je učinkovit iako mu je odnos izlaza i ulaza 0,95 : 1. S obzirom na to da BCC model dopušta varijabilne prinose s obzirom na opseg i ne postoji ni jedna jedinica DO-a koja bi imala sličnu ulazno-izlaznu kontribuciju s kojom bi se ona mogla usporediti, nju je model proglasio efikasnom.

Isprekidana linija koja povezuje apscisu s dužinom AC i nastavlja se paralelno s apscisom ilustrira krivulju (konveksnu) granice efikasnosti prema BCC modelu AOMP-a. Prema prikazu i analizi može se zaključiti da je učinkovitost prema CCR modelu uvijek manja ili jednaka od učinkovitosti koju daje BCC model, odnosno svaki DO koji je učinkovit prema CCR modelu, učinkovit je i prema BCC modelu, dok obrnuto ne vrijedi. Dakle CCR model je restriktivniji i „strože „ ocjenjuje učinkovitost i pretpostavlja konstantan prinos s obzirom na obim, a istovremeno iskazuje ukupnu tehničku efikasnost i efikasnost prema opsegu poslovanja, dok BCC model mjeri samo čistu tehničku efikasnosti daje najveću vrijednost za indekse učinkovitosti.

Analiza prozora (eng. *Window)*

Premda je učinkovitost dinamična i kategorija, koja se tijekom vremena mijenja, za kvalitetnu analizu bitno je pratiti njezino kretanje tijekom promatranog razdoblja. Ocjena učinkovitosti zasnovana samo na prosječnim vrijednostima može iskriviti sliku učinkovitosti jer se gubi vremenska dimenzija na kojoj inzistiraju svi ekonomski analitičari. U cilju izbjegavanja pogrešaka u izračunu i interpretaciji učinkovitosti i uvođenja dinamičke komponente kreirana Window analiza omeđivanja podataka (u daljnjem tekstu *analiza prozora*). Tehnika analize prozora zasniva se na principu pokretnih sredina i korisna je za određivanje trendova performansi donositelja odluka tijekom vremena (Asmild i sur., 2004.). Svaki se DO u različitom vremenskom periodu tretira kao "različitu" jedinicu DO-a koja se uspoređuje s performansama drugih DO-a u istom prozoru, ali i sa svojim performansama u drugim

vremenskim periodima (Cooper, Seiford, & Zhu, 2011). *Slika 3-14* ilustrira izlazno usmjereni model analize prozora s pretpostavkom konstantnog ulaza i dva izlaza x_1 i x_2, a ocjenjuju se dvije jedinice A i B ($n=2$) u četiri vremenska perioda s dužinom prozora iznosi dva vremenska perioda ($w=2$).



Slika 3-14: Ilustracija DEA window analize (Savić, 2012.)

Broj jedinica koji se ocjenjuje u svakom prozoru jednak je produktu broja jedinica i broja perioda, npr. 2 x 2 = 4, dakle u prvom se prozoru procjenjuju A_1, B_1 i A_2, B_2 jedinice DO, u drugom A_2, B_2 i A_3, B_3 i u trećem A_3, B_3 i A_4, B_4. U prvom prozoru granicu učinkovitosti čine DO A_2 i B_1, B_2 se projicira na granicu efikasnosti u svoju referentnu jedinicu B_2'. U drugom prozoru granicu učinkovitosti čine DO A_3 i B_3, a DO A_2 i B_2 se projiciraju na granicu učinkovitosti pri čem su im referentne jedinice A_3 i B_2''. U trećem prozoru granicu učinkovitosti definiraju DO A_4 i B_3, a A_3 i B_4 mogu postati učinkovite projekcijom na granicu učinkovitosti u svoje referentne jedinice A_4, odnosno B_3. Kao što se može primijetiti da se učinkovitost može mijenjati ako se uključi vremenska dimenzija unutar prozora i između vremenskih intervala. Na primjer, DO B je neučinkovit u prvome periodu, a učinkovit u drugom i trećem, dok je npr. jedinica DO A u prvome periodu bila neučinkovita, a u drugom, trećem i četvrtom je bila učinkovita.

S jedne strane taj se oblik analize omeđivanja podataka koristi ako je potrebno ispitati stabilnost indeksa efikasnosti i trend efikasnosti, a s druge strane i odrediti performanse promatranih jedinica za nekoliko vremenskih perioda i istovremeno pratiti njihovu dinamiku. Za potrebe te analize mora se odrediti dužina vremenskog perioda s kojim je potrebno uskladiti dužinu i broj prozora. Kao i u osnovnim modelima AOMP-a, i u analizi prozora može se odrediti na usmjerenosti na povećanje izlaza ili smanjenje ulaza.

Usmjerenost modela

Modeli analize omeđivanja podataka BCC i CCR mogu biti izlazno usmjereni (*IU*) i ulazno usmjereni (UU). Izlazno usmjerenje potiče ostvarivanje većih izlaza s ograničenim ulazima, a ulazno usmjerenje racionalno korištenje ulaza za postizanje iste razine izlaza. Dakle u IU modelima je neučinkovita svaka jedinica kojoj se može povećati bilo koji izlaz bez povećanja bilo kojeg ulaza i smanjenja nekoga od preostalih izlaza. U ulazno usmjerenim modelima je neučinkovita svaka jedinica obuhvaćena analizom kojoj je moguće smanjiti bilo koji ulaz bez smanjenja bilo kojeg izlaza i bez uvećanja bilo kojeg preostalog ulaza (Savić i Martić, 2009.).

U cilju simulacije teorijskih pretpostavki iznesenih modela i utvrđivanje učinkovitosti konstruiran je virtualni model s pet jedinica DO-a s jednim ulazom i jednim izlazom. Matrica ulaza je zapisana kao X = (1, 2, 3, 4, 6), a matrica izlaza Y = (1, 4, 6, 5, 7). Za izračun stope učinkovitosti korišteni su IU-CCR, UU-CCR i UU-BCC. Na osnovi izračuna IU-CCR i UU-CCR, za jedinice DO_2 i DO_3 utvrđena je vrijednost funkcije 1 (jedan), što znači da su one učinkovite. (*Tablica 3-6*) Prema IU-BCC modelu, učinkovite su jedinice DO_1, DO_2, DO_3 i DO_5.

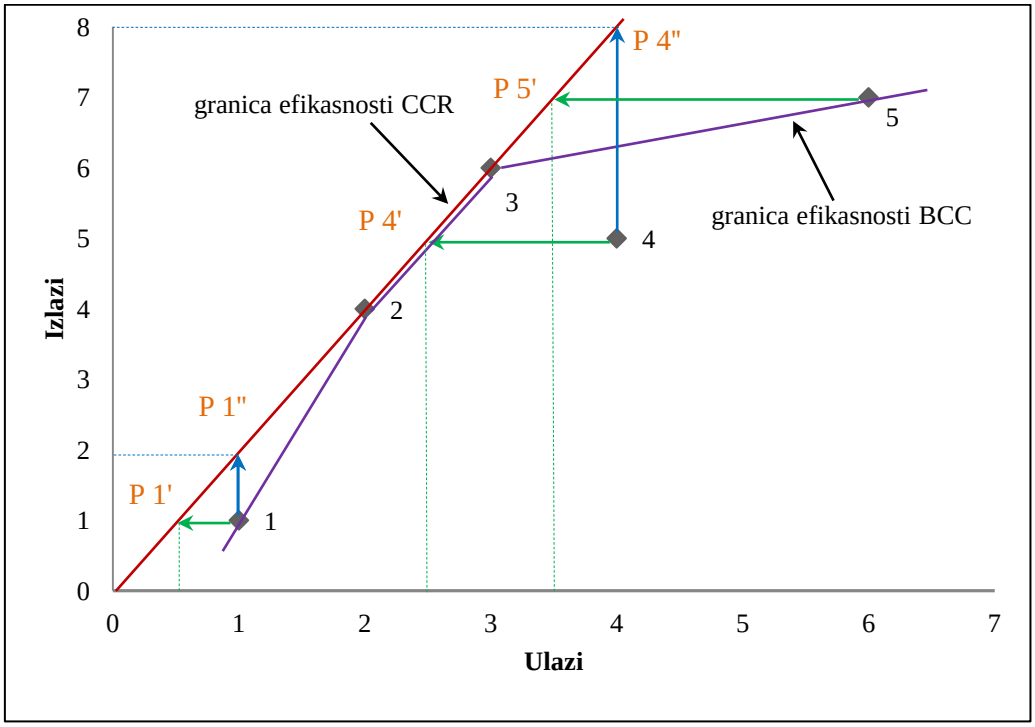
Tablica 3-6*:* Stupanj učinkovitosti prema CCR i BCC modelu

Jedinice DO	**Ulazi**	**Izlazi**	**Stupanj učinkovitosti**		
			UU-CCR	IU-CCR	UU-BCC
1	1	1	0,5	2,0	1,0
2	2	4	1,0	1,0	1,0
3	3	6	1,0	1,0	1,0
4	4	5	0,625	1,6	0,625
5	6	7	0,5833	1,7143	1,0

Izvor: Vincova, 2005

Krivulja koja povezuje učinkovite jedinice DO-a definiraju granicu efikasnosti. Ostale jedinice čija je vrijednost manja od 1 nalaze se ispod krivulje granične efikasnosti i one su neefikasne. Kao što prikazuje *Tablica 3-6,* modeli daju različit stupanj učinkovitosti

određenim jedinicama DO-a. Slijedom toga, različit je pomak kojim će one postići relativnu učinkovitost. S obzirom na to da su oba modela CCR analize izdvojila DO_2 i DO_3 kao učinkovite jedinice, oni definiraju granicu učinkovitosti (*Slika 3-15*).



Slika 3-15: Grafički prikaz ocjene učinkovitosti prema modelima CCR i BCC (Vincova, 2005.)

Sve su ostale jedinice neučinkovite, odnosno njihov je rezultat ispod granice učinkovitosti. UU-CCR model sugerira neučinkovitim jedinicama racionalizaciju ulaza (smanjenje utroška resursa), u ovom slučaju DO 1, DO 4 i DO 5 će postati efikasne transformacijom ulaza na niže razine, u točke P1', P4' i P5'.

Da bi se izračunala razina ulaza za postizanje učinkovitosti neučinkovitih jedinica DO-a možemo koristiti koeficijent relativne učinkovitosti i empirijski podatak o veličini ulaza.

Iz navedenoga slijedi da je učinkovita razina ulaza (X) jednaka:

za DO 1=> 0,5 x 1= 0,5 (*točka P1'*)

za DO 4=> 0,625 x 4 = 2,5 (*točka P4'*)

za DO 5 => 0,583 x 6 = 3,5 (*točka P5'*)

Dakle neučinkovite jedinice će postati učinkovite ako smanje korištenje ulaza uz zadržavanje postojeće razine izlaza.

S obzirom na to da IU-CCR model inicira postizanje efikasnosti povećanjem izlaza, za neefikasne jedinice DO 1 i DO 4 potrebno je postići višu razinu izlaza transformacijom u

točke P1" i P4" na granici učinkovitosti (*Slika 3-15*). Vrijednosti učinkovite razine izlaza mogu se izračunati slično kao za učinkovitu razinu ulaza:

za DO 1 => 1 ÷ 0,5 = 2 (*točka P1"*)

za DO 4 => 5 ÷ 0,625 = 8 (*točka P4"*)

Prag učinkovitosti izračunat pomoću UU-BCC modela je niži, odnosno veći broj jedinica DO-a je učinkovit prema tom modelu pri čem granicu učinkovitosti definiraju učinkovite jedinice DO 1, DO 2, DO 3 i DO 5. Zbog padajuće stope povrata granica učinkovitosti kod UU- BCC nije pravac nego konveksna krivulja.

Kao što je vidljivo iz prikaza na *Slici 3-15,* orijentacija AOPM modela određuje pravac projekcije neučinkovite jedinice na granicu učinkovitosti. U ulazno usmjerenom modelu učinkovitost se povećava smanjenjem ulaza, a u izlazno usmjerenom modelu projekcija je orijentirana na proporcionalno povećanje izlaza. To grafički znači da se kod UU modela projekcija obavlja „nalijevo – horizontalno“ u koordinatnome sustavu, a kod IU modela „na gore – vertikalno“. Kod CCR modela bez obzira na orijentaciju, granica učinkovitosti je ista, samo što je projekcija na tu granicu različita.

Treba napomenuti da postoje brojne modifikacije osnovnih modela analize omeđivanja podataka koje su nastale kao rezultat prilagodbe specifičnim potrebama analize i nastojanjima da se unaprijedi sama metodika (Savić i Martić, 2011.).

3.4.2. Identifikacija performansi

Subjektivnost autora kod identificiranja ključnih performansi ulaza (eng. *inputa*) i izlaza (eng. *outputa*) ključno je ograničenje u korištenju metode AOMP u svim područjima primjene. Iako je metoda pogodna za analizu u sustavima koji nemaju jasno definiranu transformaciju ulaza u izlaze i u kojima nije moguće jasno utvrditi koji su ulazi i u kojoj mjeri utjecali na koje izlaze, pretpostavka je da bi drugačiji izbor ulaza i izlaza generirao drugačiji rezultat. Zbog navedenoga ograničenja, za što objektivniji odabir ulaza i izlaza nužno je poznavanje procesa unutar entiteta koji su predmet analize. Značajna je i činjenica da je metoda AOMP, kao i sve druge metode koje se koriste u sustavima koji imaju nedefinirane procese transformacije ulaze u izlaze, ograničena na manji broj indikatora koji se uzimaju u razmatranje iako na rezultate upravljanja utječe velik broj čimbenika. Neki autori sporadično navode utjecaj identificiranih performansi na dobivene rezultate, ali u svojim istraživanjima nisu nastojali uspostaviti sustav koji bi definirao odnos skupa pokazatelja i dobivenih

rezultata. Analiza mogućnosti usmjeravanja samog istraživanja odabirom ključnih pokazatelja je važno u cilju potvrđivanja pretpostavki iz hipoteze H IV ove disertacije.

Iako ne postoje čvrsto zadani okviri ni mehanizmi odabira ulaza i izlaza, kao ni čvrstih veza koje odražavaju njihovu eksplicitnu povezanost, prema Rabar (2010.) ulazi i izlazi moraju u najboljoj mjeri odražavati zajedničke interese menadžera i analitičara. U postupku odabira relevantnih ulaza (resursa) i izlaza (učinaka) koje ostvaruje menadžment upravljanjem javnim resursima, svakako treba poći osnovnih nadležnosti i ostvarenih učinaka. U recentnim istraživanjima učinkovitosti vlasti, na lokalnoj ili nacionalnoj razini, istraživači i znanstvenici su koristili različit skup ključnih pokazatelja. Tako su Byrnes i Storbeck (2000.) u analizi uspješnosti regionalnog ekonomskog razvoja kineskih gradova koristili jedan output (vrijednost bruto industrijske proizvodnje) i dva inputa (broj zaposlenih i razine investicija/kapitala). Karkazis i Thanassoulis (1998.) su u ocjeni učinkovitosti razvojnih politika na regionalnoj razini u Grčkoj izradili model s dvama ulazima (javne investicije i poticaji za ulaganja) i jednim izlazom (privatna ulaganja u uslužne djelatnosti i poljoprivredu). Mjereći kvalitetu života u 15 američkih gradova Zhu (2001.) kao ulaze je koristio odnos najviše i najniže stanarine, cijenu okrugloga francuskog kruha, cijenu martinija, cijenu najma ureda ($/m^2) i broj nasilnih zločina, a broj golfskih igrališta s 18 rupa, broj muzeja, broj liječnika, broj visokoobrazovanih, broj knjižnica i prosječni dohodak domaćinstva kao ulaze. Halkos i Tezeremesu (2005.) su u procjeni regionalnoga razvoja u Grčkoj identificirali četiri inputa: broj bolničkih postelja na 1000 stanovnika, broj liječnika na 1000 stanovnika, broj javnih škola na 1000 studenata, broj javnih autobusa na 1000 stanovnika i tri outputa: BDP izražen kao udio u prosječnom nacionalnom BDP-u, odnos ubranoga i ruralnoga stanovništva i broj novih kuća na 1000 stanovnika.

Ocjenjujući troškovnu učinkovitost australskih gradova Worthington (2000.) je sukladno osnovnim funkcijama lokalne samouprave[40] odabrao sedam outputa i to: stanovništvo (y_1), dostupnost i broj korisnika usluge odvoza i zbrinjavanja otpada (y_2), dostupnost i broj korisnika sustava odvodnje (y_3), broj korisnika vodoopskrbe (y_4), duljina (km) urbanih prometnica (y_5), duljina nerazvrstanih uređenih prometnica (y_6) i duljina neuređenih prometnica (y_7). Međutim isti autor ističe niz upozorenja koja treba uzeti u obzir

[40] Identificirane funkcije lokalne samouprave u Australiji su: financijske i korporativne usluge, knjižnice, zaštita okoliša, planiranje i regulatorne funkcije, usluge za rekreaciju građana, usluge zajednici, gospodarenje otpadom iz domaćinstva, odvodnja, vodoopskrba, i izgradnja i održavanje prometne infrastrukture.

kod kvantifikacije outputa u lokalnoj samoupravi. Ona se prije svega odnose na poteškoće u utvrđivanju razine kvalitete pruženih usluga koje su posljedica brojnih čimbenika koji se ne mogu uzeti u razmatranje poput razlike u klimi, topografiji, udaljenosti sliva za kanalizaciju, međusobne troškovne zavisnosti pruženih usluga i drugih. U identifikaciji inputa istaknuta je još izraženija poteškoća jednoznačnoga i jasnoga iskazivanja troškova i resursa koji utječu na određene rezultate kao i njihova dostupnost u numeričkome obliku. Stoga su u predmetnome istraživanju identificirana tri inputa: rad (x_1) – mjeren ekvivalentom punoga radnog vremena, ostali materijalni troškovi (x_2) – uglavnom materijal i inventar isključujući amortizaciju te kapitalne rashode u $ (x_3) – krediti, prekoračenja i pozajmice. Prema istome autoru, u nekim istraživanjima, zbog nedostupnosti ili nedostatka financijskih pokazatelja, korišteni su i ukupna površina skladišnoga prostora (m^2) u zamjenu za input kapitala u području brige za djecu, duljina angažiranih vodova električne energije, broj postelja u javnoj bolnici i drugi.

U cilju ocjenjivanja uspješnosti lokalnih vlasti u njemačkoj pokrajini Baden-Württemberg, Gays i ostali (2007.) identificirali su šest output varijabli koje se odnose na odgovornosti njemačke lokalne samouprave s obzirom na društvene, obrazovne, rekreacijske i infrastrukturne ovlasti, a to su: broj učenika u lokalnim javnim školama, broj mjesta u vrtićima, površine javnih rekreacijskih objekata, ukupna populacija, stanovništvo starije od 65 godina i broj zaposlenih koji uplaćuje socijalno osiguranje. Uz navedene outpute isti autor ukazuje na potrebu akceptiranja društveno-ekonomskih i političkih čimbenika čiji je utjecaj najčešće dvosmislen. Tako visoka gustoća naseljenosti s jedne strane utječe na smanjenje jediničnih troškova izgradnje, a s druge strane ono utječe na znatan porast cijena nekretnina i poskupljuje proizvodnju. Jednako tako politički pluralizam utječe pozitivno na povećanu aktivnost zbog političke konkurencije, ali nerijetko koči provedbu projekata. Martić i ostali (2001.) su, istražujući učinkovitost korištenja regionalnih resursa u regijama Srbije 2001. godine, identificirali sljedeće inpute: obradive površine, ukupna imovina, potrošnja električne energije i stanovništvo te su ih uspoređivali s četiri outputa: BDP, ukupan broj liječnika, ukupan broj učenika u osnovnim školama i ukupan broj zaposlenih u društvenom sektoru.

Radi općega pregleda potrebno je istaknuti još neke varijable koje se koriste u analizama učinkovitosti lokalnih samouprava kao ulazi i izlazi: odnos između plavih i bijelih ovratnika u upravi, trošak rada izražen prosječnom plaćom u upravi, potpore opće namjene kao udio ukupnih prihoda, stopa vraćanja duga (neto trošak zaduženja, kamata i glavnica, podijeljena s poslovnim prihodima), razina kratkotrajne imovine, koeficijent likvidnosti lokalne

samouprave, broj zaposlenih na 1000 stanovnika, prosječna stopa lokalnih poreza i druge. Prema Worthingtonu (2000.) pokazatelji učinkovitosti lokalnih samouprava u izravnoj su korelaciji s njihovim osnovnim funkcijama, ali nema ni jednoga sustava koji ih izravno može kvantificirati. Stoga se ovisno o ovlastima lokalne samouprave i postavljenim ciljevima istraživanja mogu identificirati ključni ulazi i izlazi. Isti je znanstvenik ulaze i izlaze podijelio na *diskrecijske* - one nad kojima lokalna vlast ima nadzor (npr. upravljanje troškovima, porezna politika i ekvivalent punog radnog vremena) i *nediskrecijske* (stopa porasta stanovništva, ekološka osjetljivost, prirodni resursi).

Sukladno navedenomu, u procesu utvrđivanja referentnih pokazatelja uspješnosti u istraživanju učinkovitosti upravljanja gradovima u Republici Hrvatskoj uzet će se u obzir ključne ovlasti gradova, kao jedinica lokalne samouprave i identificirati ciljevi koji zadovoljavaju donositelje odluka i korisnike javnih usluga vodeći pri tome brigu o ujednačenosti izabranih ulaza i izlaza u svim promatranim entitetima izbjegavajući one pokazatelje koji su pod znatnim utjecajima specifičnosti promatranih entiteta.

3.4.3. Pregled dosadašnjih istraživanja

S obzirom na aktualnost i mogućnost široke primjene AOMP metode u profitnom i neprofitnom (javnom) sektoru ista je pobudila velik interes i u znanstvenim krugovima. Prema Emrouznejadu, Parkeru i Tavaresu (2008.) na tome je području napisano više od četiri tisuće znanstvenih radova, a znatan se dio njih odnosi upravno na neprofitni (javni) sektor. S obzirom na velik broj istraživanja u cijelome nizu područja, u nastavku ovoga poglavlja bit će iznesen pregled dostupnih znanstvenih istraživanja o korištenju AOMP-a u javnoj upravi na lokalnoj razini.

Pregled istraživanja u svijetu

- Hughes i Edwards (2000.) su istraživali utjecaj veličine lokalne zajednice i uz nju vezane alokacije moći na efikasnost pružanja javnih usluga u Minesoti, te su zaključili da smanjena javna potrošnja i veći opseg javnih ovlasti povećava efikasnost javne uprave, a veličina površine, centralizacija vlasti i povećana javna potrošnja smanjuju efikasnost;
- Worthington i Dollery (2002.) su analizom osnovnih funkcija (planiranje i regulacija) u 173 lokalne samouprave Novoga Južnog Walesa metodom omeđivanja podataka diferencirali nediskrecijske ulaze (čimbenike izvan kontrole upravljačke strukture) i diskrecijske ulaze (čimbenike na koje lokalna vlast ima utjecaj).

Rezultati su pokazali da je utvrđena relativna učinkovitost u pet kombinacija nediskrecijskih ulaza u signifikantnoj pozitivnoj korelaciji;

- Drake, L. i R. Simper (2000.) su koristeći AOMP metodu istraživali produktivnost engleske i velške policije te su ustvrdili da je na osnovi dobivenih rezultata moguće optimizirati veličinu i strukturu policijskih snaga;
- Haas i ost. (2001.) mjerili su efektivnost njemačkih nogometnih klubova u Bundesligi na osnovi provedbe obveza prema igračima i trenerima, ostvarenim bodovima, brojem gledatelja i ukupno ostvarenim prihodima te su ustvrdili da efikasnost klubova nije u svezi s plasmanom u ligi;
- Martić i Savić su 2001. godine istraživali učinkovitost korištenja regionalnih resursa u 30 regija u Srbiji metodom omeđivanja podataka, CCR modelom koristeći 4 ulaza i četiri izlaza. Rezultati istraživanja su pokazali da je 17 od 30 regija u Srbiji uspješno;
- Woodbury, Dollery i Rao (2003.) su istražujući performanse uspješnosti lokalne uprave u domeni vodoopskrbe i odvodnje u Australiji ukazali na nedostatke konvencionalnih metoda mjerenja u odnosu na DEA analizu;
- Afonso i Aubyn su 2005. godine istraživali učinkovitost obrazovanja i liječenja u 24 zemlje OECD-a AOMP metodom te su utvrdili da su državna potrošnja, kao ulaz i kvalitete života, kao izlaz ključni elementi učinkovitosti bez obzira na lokaciju;
- Halkos i Tzeremes (2005.) su istraživali učinkovitost lokalne vlasti u Grčkoj pomoću DEA metode i ustvrdili visoku korelaciju između razine razvijenosti (izraženog BDP-om) i učinkovitog upravljanja resursima dok razina dostupnih resursa nije imala presudnu ulogu;
- Moore, Nolan i Segal su 2005. godine razmatrali učinkovitost 46 američkih gradova analizirajući kvalitetu 11 komunalnih usluga tijekom šest godina pomoću analize omeđivanja podataka, a rezultati ukazuju na mogućnosti povećanja uspješnosti benchmarkingom i utjecajem na procese transformacije inputa u outpute;
- Afonso i Fernandes (2008.) su 2006. godine istraživali troškovnu učinkovitost 51 jedinice lokalne uprave u Portugalu, koristeći AOMP- BCC model analizirajući javne usluge, edukaciju, socijalnu aktivnost i zaštitu okoliša. Rezultati istraživanja su pokazali da je istu razinu učinkovitosti moguće postići s 41% resursa, odnosno da se unaprjeđenje javnih usluga može provesti bez povećanja troškova;

- Loikkanen i Susiluoto su 2006. godine istraživali efikasnost lokalnih samouprava u Finskoj u pružanju osnovnih usluga metodom AOMP-a. Za te su potrebe identificirali performanse iz domene zdravstvene i socijalne skrbi te obrazovanja modificirajući ih prema troškovima, a rezultati su ukazali na znatne razlike između istraživanih entiteta pri čem su najuspješnije bile male općine na sjeveru Finske. Periferni položaj, visina plaće, veličina populacije, visoka nezaposlenost, širina spektra javnih usluga pokazali su utjecaj na smanjenje učinkovitosti općinskih usluga. S druge strane povećani udio radne snage u dobnoj skupini od 35 do 49 godina, gustoća naseljenosti, udio usluga privatnog sektora i razina obrazovanja stanovništva pozitivno su utjecali na povećanje učinkovitosti;
- Ukupnu produktivnost kineskih gradova u 1984. i 2003. godini istraživali su Kangjuan i Zheng (2006.) pomoću metode omeđivanja podataka. Rezultati istraživanja pokazuju da je ukupna razvijenost velikih gradova preduvjet ukupne faktorske produktivnosti, a neproduktivni gradovi mogu postići razinu prosječne produktivnosti ulaganjem u razvoj infrastrukture i transfer tehnologije iz razvijenih gradova.

Pregled istraživanja u Hrvatskoj

U Hrvatskoj je broj istraživanja vezanih uz primjenu analize omeđivanja podataka znatno manji. U području procjene uspješnosti upravljanja gradovima (lokalnom samoupravom) do sada nema poznatih radova, a po tematici je najbliži rad Škuflić i ostalih objavljen 2010. godine na temu procjene efikasnosti hrvatskih županija primjenom AOMP metode koji će kasnije u ovome radu biti detaljnije prezentiran. Istraživanjima u području korištenje metode AOMP-a u različitim područjima društveno-gospodarskog života u Hrvatskoj bavili su se:

a. u gospodarskom sektoru

Hunjet (1998.), Bahovec i Neralić (2001.), Šporčić i ostali (2008. i 2010.) i drugi.

b. u uslužnom sektoru

Neralić (1996.), Jermić i Vujčić (2002.), Petrov (2002.), Hunjak i Jakovčević (2003.), Šegota (2003. i 2008.) i drugi.

c. u javnome sektoru

- Jafarov (2008.) istražuje relativnu učinkovitost sustava socijalne potrošnje Hrvatske (zdravstvena skrb, obrazovanje i socijalna zaštita) u EU okružju jednostavnom korelacijskom i AOMP analizom;

- Slijepčević (2009.) u doktorskoj disertaciji istražuje učinkovitost sustava javne potrošnje u Hrvatskoj u odnosu na države članice EU pri čem je za utvrđivanje granice efikasnosti korištena metoda omeđivanja podataka;
- (2010.) Rabar u svojem radu o ocjeni efikasnosti hrvatskih bolnica analizom omeđivanja podataka koristi se četirima parametrima za ukupno 63 zdravstvene ustanove u Hrvatskoj primjenjujući CCR[41] i BCC[42] modele input-usmjerene zbog zadanoga uvjeta smanjenja javne potrošnje u zdravstvu. Prema rezultatima analize 78% bolnica u Hrvatskoj je neefikasno, a autorica preporučuje benchmarking s uspješnim bolnicama prema analiziranim performansama i utvrđenim izvorima neefikasnosti.

U kontekstu interesa autora ovoga rada za procjenu uspješnosti javne uprave, najzanimljivije je istraživanje skupine autora Škuflić, Rabar i Šokčević (2010.) na području procjene efikasnosti hrvatskih županija primjenom analize omeđivanja podataka[43]. Osnovna pretpostavka rada zasnovana je na mjerenju gospodarskog rasta u odnosu na granice proizvodnih mogućnosti sukladno teorijama gospodarskog rasta.

U radu su identificirana dva izlaza (eng. *outputa*) i pet ulaza (eng. *inputa*) kao indikatori životnog standarda i razine ekonomskog rasta i to:

$\boldsymbol{I_1}$ – bruto domaći proizvod po glavi stanovnika

$\boldsymbol{I_2}$ – bruto plaće po zaposlenome

$\boldsymbol{U_1}$ – broj diplomiranih studenata kao pokazatelj ljudskih potencijala

$\boldsymbol{U_2}$ – izravna strana ulaganja (FDI) kao pokazatelj kapitala i tehnologije

$\boldsymbol{U_3}$ – ulaganja u opremu, kao pokazatelj kapitala

$\boldsymbol{U_4}$ – izvoz, kao indikator otvorenosti

$\boldsymbol{U_5}$ – broj aktivnih pravnih osoba, kao pokazatelj poduzetništva

Analizom je bila obuhvaćena ukupno 21 jedinica regionalne samouprave[44] čime je zadovoljen uvjet da broj entiteta koji se uspoređuje mora biti barem tri do pet puta veći od ukupnoga broja ulaza i izlaza (Hunjak i Jakovčević, 2003.; Rabar, 2010.). Ako je broj ulaza i izlaza velik u usporedbi s brojem jedinica koje su uključene u analizu, veća je vjerojatnost da postoji

[41] Charnes-Cooper- Rhodesov model zasnovan na pretpostavci konstantnog prinosa, u nekoj literaturi se spominje i kao CRV- Constant Return to Scale

[42] Banker-Charnes-Cooperov model koji pretpostavlja varijabilne prinose, u nekoj literaturi se taj model označava kao VRS- Variable return to scale

[43] Naslov u originalu: Assessment of the Efficiency of Croatian Counties Using Dana Envelopment Analysis.

[44] Analizirani su podatci za 20 županija i Grad Zagreb koji ima status županije.

jedna ili više kombinacija varijabli prema kojima je promatrana jedinica najbolja te će biti ocijenjena kao učinkovita. Za procjenu uspješnosti korišteni su statistički podaci za 2006. godinu, a zbog nesigurnosti u karakteristike podataka korišteni su CCR i BCC modeli AOMP-a. Autori su za analizu koristili DEA- Solver-Pro softver.
Rezultati provedene analize omeđivanja podataka ukazuju da je srednja relativna učinkovitost hrvatskih županija 0,8492 što znači da bi županije u prosjeku bile učinkovite moraju koristiti 84,92% resursa za postizanje istih rezultata. Osam županija (38%) pokazuje relativnu učinkovitost i predstavljaju dobru praksu u kojoj mogu ostale županije tražiti uzor učinkovitosti. Trinaest županija je neučinkovito u jednome (12%) odnosno u dva (50%) ulaza.

S obzirom na izabranu strukturu ulaza i izlaza nije moguće identificirati razinu odgovornoga centra odlučivanja (DO) pod čijim je utjecajem upravljanje ulazima i izlazimau cilju postizanja boljih rezultata. Drugim riječima, promatrane županije ne predstavljaju pravnoformalne entitete kojima upravlja jasno i formalno identificirani menadžment (DO) u čijoj je ovlasti donošenje odluka o visokome školstvu (I_1), privlačenju novih stranih investicija (I_2) i gospodarstvu (I_3 I_4 *i* I_5). Stoga se ovaj rad može pozitivno sagledati u svjetlu općeg doprinosa analizi ekonomske razvijenosti određenih regija u Republici Hrvatskoj, ali ne i kao realni menadžerski alat u postizanju veće učinkovitosti i racionalnijeg upravljanja resursima jer nema nositelja praktične primjene.

4. ISTRAŽIVANJE

4.1. Metodologija i plan istraživanja

Za istraživanje učinkovitosti upravljanja velikim gradovima u Republici Hrvatskoj odabrana je metoda analize omeđivanja podataka (AOMP) koja omogućuje analizu međusobno usporedivih jedinica unatoč heterogenim podacima koji se izražavaju različitim mjernim jedinicama i na različit način utječu na učinke. U analizu relativne učinkovitosti upravljanja bit će uključeno petnaest velikih gradova u kojima centre odlučivanja predstavlja politički menadžment koji će biti tretirani kao petnaest međusobno usporedivih donositelja odluka - DO (eng. *Decision Making Units),* čija će se učinkovitost upravljanja analizirati s više ulaza i izlaza (eng. *inputa i outputa*). Donositelje odluka u ovome istraživanju dakle predstavlja lokalna vlast koja, koristeći raspoložive resurse (ulaze), ostvaruje ekonomski mjerljive rezultate (izlaze). Učinkovitost upravljanja lokalnom samoupravom u ovom će se radu izraziti efikasnošću korištenja raspoloživih resursa mjereno razinom postizanja određenih ciljeva koji

proizlaze iz osnovnih funkcija lokalne samouprave. Sukladno navedenomu, u ovom će se radu ocjenjivati relativna učinkovitost lokalnih vlasti, pomoću AOMP metode, usmjerene na ostvarivanje rezultata, odnosno ciljeva. Kao što je navedeno u prijašnjim poglavljima, osnovni modeli AOMP-a koji se koriste u istraživanjima učinkovitosti su CCR i BCC modeli koji se međusobno razlikuju u pretpostavljenoj transformaciji resursa u rezultate. S obzirom na karakteristike procesa upravljanja u lokalnoj samoupravi, u analizi učinkovitosti upravljanja gadovima koristit će se oba modela usmjerena na ostvarene rezultate. Uz navedeno, vodit će se računa o odnosu broja ulaza i izlaza prema ukupnome broju entiteta koji mora biti barem tri do pet puta veći od ukupnoga broja ulaza i izlaza (Hunjak, 2003). U slučaju da se ne poštuje to pravilo, zbog odlike analize omeđivanja podataka da teži svaku promatranu jedinicu prikazati u najboljem svjetlu, postoji velika opasnost da će većina jedinica biti okvalificirana kao učinkovita. Drugim riječima, što je odnos između broja ulaza i izlaza u odnosu na broj jedinica DO-a koje se analiziraju uži, veća je vjerojatnost da postoji jedna ili više kombinacija varijabli prema kojima je određena jedinica učinkovita.

Premda se istražuje uspješnost ukupno 15 gradova, ukupan broj pokazatelja je ograničen na 5. Uzevši u obzir osnovne ovlasti gradova iz samoupravnog djelokruga, definiranu razinu donošenja odluka, dostupnost podataka koji se u svim gradovima prikupljaju i iskazuju na jedinstven način, za ovo su istraživanje odabrana četiri ulaza (resursa) koji će biti istraživani u dvjema kombinacijama, i tri izlaza (učinaka).

4.2. Odabir modela AOMP-a

U analizi učinkovitosti upravljanja gradovima u Republici Hrvatskoj bit će korištena dva modela usmjerena k ostvarivanju rezultata (eng. *output oriented*) i to:

1. CCR (CRS[45]) koji pretpostavlja konstantne prinose s obzirom na opseg djelovanja
2. BCC (VRS[46]) koji pretpostavlja varijabilne prinose s obzirom na opseg djelovanja

Ti su modeli odabrani iz sljedećih razloga:

- vrsta prinosa s obzirom na opseg djelovanja (*konstantan vs varijabilan*) nije jasno identificirana, ako dobiveni rezultati ne odstupaju znatnije tada ne postoji efekt obujma pa se analiza učinkovitosti može provesti CCR modelom,

[45] engl. Constant Return to Scale

[46] engl. Variable Return to Scale

- strateško opredjeljenje političkoga menadžmenta po svojoj je prirodi usmjereno na postizanje boljih rezultata (izlaza), a rjeđe ili gotovo nikad na smanjenje resursa (ulaza),
- model CCR je restriktivniji u određivanju učinkovitosti u odnosu na BCC,
- zbog specifičnih obilježja odabranih modela projekcije na granicu efikasnosti bit će različite,
- širi opseg dobivenih rezultata omogućit će kvalitetniju i realniju analizu i izvođenje zaključaka.

Za određivanje vremenske dinamike odabranih performansi gradova koristit će se *Window* analiza (*analiza prozora*) kojom će se u četiri prozora utvrditi trend tijekom promatranog razdoblja. Na taj će se način u svakome jednogodišnjem periodu uspoređivati svaki DO sa svojim performansama u drugim periodima i s performansama drugih DO-a (ukupno 60).

4.3. Odabir ulaza i izlaza za analizu učinkovitosti hrvatskih gradova

U postupku odabira ključnih pokazatelja – performansi koje u najboljoj mjeri odražavaju procese odlučivanja u lokalnoj samoupravi na osnovi kojih će se procjenjivati učinkovitost upravljanja potrebno je prije svega zadovoljiti neke osnovne postulate metode analize omeđivanja podataka. Jedan od njih zahtijeva da su vrijednosti svih varijabli tijekom promatranoga razdoblja veće od nule i pozitivnoga predznaka. Druga pretpostavka za realnu analizu zahtijeva povezanost između varijabli ulaza i izlaza pri čem pozitivne promjene varijabli ulaza moraju rezultirati pozitivnim promjenama izlaza bez smanjenja vrijednosti bilo kojega ulaza (tzv. osobina *izotonosti*[47]). To će se svojstvo kasnije u ovome poglavlju identificirati izračunom koeficijenata korelacije između odabranih ulaza i izlaza. Opće pravilo o odnosu između ukupnoga broja ključnih pokazatelja i promatranih jedinica već je prije izneseno, a može se izraziti sljedećim izrazom $nX + nY < nDO/3$.

Osim tih osnovnih pretpostavki u identificiranju ključnih pokazatelja, uspješnost i vjerodostojnost procjene učinkovitosti upravljanja gradovima u znatnoj mjeri ovisi o identifikaciji ključnih nadležnosti i poslova koje obavlja lokalna samouprava u Hrvatskoj. Djelokrug i nadležnosti jedinica lokalne samouprave – gradova određene su Zakonom o lokalnoj i područnoj (regionalnoj) samoupravi[48] koji svoje ishodište pronalazi u općim

[47] engl. Isotonicity

[48] Zakonom o lokalnoj i područnoj (regionalnoj) samoupravi, (NN 33/01 i 60/01) definiran je samoupravni djelokrug JLSU-a, a amandmanima na ZLP(R)S 2005. godine uvedena je nova kategorija jedinica lokalne

načelima Europske povelje o lokalnoj samoupravi[49] i stvarnoj raspodjeli vlasti u Republici Hrvatskoj. Prema Zakonu o lokalnoj i područnoj (regionalnoj) samoupravi, veliki gradovi, u svom samoupravnom djelokrugu, izvršavaju zadatke od lokalne važnosti kojima se izravno zadovoljavaju potrebe građana, mogu se sažeti u tri osnovne kategorije prema *Slici 4-1,* a odnose se na upravljanje imovinom, organizaciju javnih poslova i pružanje javnih usluga korisnicima.



Slika 4-1: Poslovi iz nadležnosti JLSU-a

U razdoblju za koje će se obaviti ocjena uspješnosti upravljanja velikim gradovima u Republici Hrvatskoj (mandat od 2005. do 2008. godine), građani su na izborima birali predstavničko tijelo (gradsko vijeće) koje je (u pravilu) iz redova vijećnika biralo gradonačelnika i članove poglavarstva koji su obnašali izvršnu vlast u gradovima (*Slika 4-2*).

S obzirom na to da je izbor izvršne vlasti (prije svega gradonačelnika) bio uvjetovan političkom većinom u predstavničkom tijelu te da su ključne odluke i politika razvoja kreirane i provođene na razini izvršne vlasti (koja ustrojava upravna tijela i njima upravlja), gradonačelnik (politički menadžer) i gradsko poglavarstvo će u ovom radu biti tretirani kao donositelji odluka (DO).

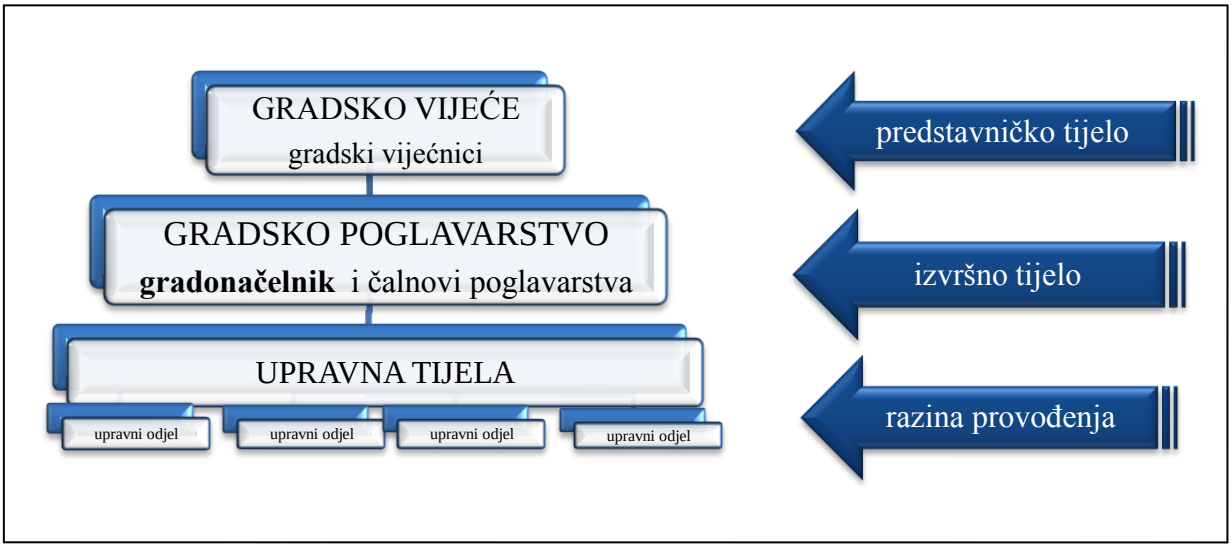
Kod postavljanja modela AOMP-a, kojim će biti procijenjena uspješnost upravljanja gradovima, uzeti su pokazatelji uspješnosti koji odražavaju željene ciljeve iz opsega nadležnosti kao izlazi i ključni resursi koji su pod izravnom kontrolom DO-a tzv. diskrecijski

---

samouprave: veliki gradovi. Ta kategorija obuhvaća gradove koji su gospodarska, financijska, kulturna, zdravstvena, prometna i znanstvena središta šireg okruženja, i koji imaju iznad 35.000 stanovnika.

[49] Zakon o potvrđivanju europske povelje o lokalnoj samoupravi, Narodne Novine broj 4/2008

(eng. *controllable*), kao ulazi. Kao kontrolni pokazatelji za potvrđivanje pretpostavki u IV. hipotezi, uzet će se podaci o resursima koji su izvan domene odlučivanja DO-a tzv. nediskrecijski (eng. *noncontrollable*).



Slika 4-2: Struktura upravljanja gradovima 2005. – 2008. godine

Prema mnogim znanstvenicima koji se bave proučavanjem i praktičnom primjenom AOMP modela, odabir ključnih performansi je jedini element unošenja subjektivnosti u analizu i osnovno ograničenje samog modela. Uz navedeno, potrebno je voditi računa o odnosu broja ulaza i izlaza prema ukupnom broju entiteta čija se uspješnost upravljanja istražuje. Premda se istražuje uspješnost ukupno 15 gradova, ograničen je ukupan broj pokazatelja na 5.

Uzevši u obzir osnovne nadležnosti gradova iz samoupravnog djelokruga, definiranu razinu donošenja odluka i dostupnost podataka koji se u svim gradovima prikupljaju i iskazuju na jedinstven način, za ovo istraživanje odabrana su dva diskrecijska i dva kontrolna nediskrecijska ulaza (resursa):

Ulazi

a) diskrecijski (*kojima upravlja DO*)

- x_1 porez i prirez na dohodak (*per capita*)
- x_2 komunalni doprinos i druge naknade (*per capita)*

b) nediskrecijski (izvan upravljanja DO)

- x_3 prosječan broj radno aktivnog stanovništva (RAS)
- x_4 dohodak po stanovniku

Podaci za ulaze x_1 *i* x_2 uzeti su iz službenih glasila gradova za promatrano razdoblje od 2005. do 2008. godine iz odluka o godišnjem obračunu proračuna, kojima se iskazuje stvarna realizacija planiranih proračunskih stavki nakon završene proračunske godine. Za nediskrecijski ulaz x_3 korišteni su službeni statistički podaci FINA-e (godišnja financijska izvješća pravnih subjekata) i podaci Hrvatskoga zavoda za mirovinsko osiguranje, a za x_4 podaci iz Narodnih novina 88/10.

Porez i prirez na dohodak (x_1) izražava fiskalni potencijal gradova koji je izravno ovisan o primanjima građana koja podliježu oporezivanju na osnovi poreza na dohodak i na njega obračunatog prireza. Sastoji se od dijela poreza na dohodak koji predstavlja dio prihoda proračuna jedinica lokalne samouprave i prireza koji se obračunava po stopi[50] do 15% na porez na dohodak.

Komunalni doprinos i druge naknade (x_2) je proračunska prihodovna stavka koja predstavlja dio proračunskih prihoda čija visina ovisi o investicijama u izgradnji stambenih i poslovnih građevina (*komunalni doprinos*) i površini izgrađenih stambenih i gospodarskih prostora (*komunalna naknada*) te o dostupnosti i dinamici priključivanja građevina na komunalnu infrastrukturu.

Diskrecijski ulazi x_1 i x_2 predstavljaju proračunske prihode koji su pod upravljanjem političkog menadžmenta, dok su nediskrecijski ulazi x_3 i x_4 izvan nadležnosti i utjecaja DO-a.

Prosječan broj radno aktivnog stanovništva (x_3) predstavlja četverogodišnji prosjek broja radno aktivnog stanovništva u pojedinom gradu koji je dobiven iz podataka o broju zaposlenih (HZMO) i broju nezaposlenih (HZZ),

Dohodak po stanovniku (x_4) je omjer ukupnog iznosa dohotka kojega su tijekom jednoga poreznog razdoblja (kalendarska godina) ostvarili porezni obveznici, fizičke osobe s prebivalištem ili boravištem na području grada i broja stanovnika koji žive na području grada.

Izlazi (učinci):

- y_1 *stopa nezaposlenosti*
- y_2 *prosječne plaće*
- y_3 *investicijski potencijal (investicije u gospodarstvu po zaposlenom)*

[50] Pravilnik o porezu na dohodak, „Narodne novine“ broj 95/05) za gradove veće od 30.000 stanovnika maksimalna stopa prireza iznosi 15%.

Kod prikupljanja podataka za identificirane izlaze korišteno je nekoliko izvora i to za izlaze y_2 i y_3 statistički podaci iz godišnjih financijskih izvješća koje prikuplja i obrađuje FINA, dok je izlaz y_1 izračunat je na osnovi podataka Hrvatskog zavoda za mirovinsko osiguranje (HZMO) o broju osiguranika i Hrvatskog zavoda za zapošljavanje (HZZ) o broju nezaposlenih. Svi podaci odnose se na razdoblje od 2005. do 2008. godine.

Za sve ulaze i izlaze podaci će se normalizirati[51], a u izračun će se uzeti četverogodišnji prosjek. Premda se osnovni podaci odabranih pokazatelja odnose na razdoblje jedne kalendarske godine, što omogućuje dobivanje rezultata učinkovitosti kroz više vremenskih razdoblja, provesti će se tzv. dinamička analiza prozora (eng. *Window*). U analizi prozora, za potrebe ovog istraživanja, podaci će se za svaki DO u jednoj godini tretirati kao jedan DO, prema čemu će ukupan broj DO-a biti jednak 4 x 15= 60. Na taj će se način utvrditi dinamika tijekom jednog mandata i utjecaj (dis)kontinuiteta vlasti na učinkovitost upravljanja.

Za odgovor na istraživačko pitanje povezanosti učinkovitosti upravljanja s razinom ekonomske razvijenosti gradova koristit će se dva neovisno utvrđena indikatora:

1. Indeks razvijenosti kao pokazatelj stupnja razvoja jedinica lokalne samouprave na osnovi kojega općine i gradovi ostvaruju pravo na posebnu državnu potporu u cilju ujednačavanja gospodarskog razvoja na području cijele zemlje. Kriteriji za izračun indeksa razvijenosti su:

- stopa nezaposlenosti
- dohodak po stanovniku
- proračunski prihodi jedinica lokalne, odnosno područne (regionalne) samouprave po stanovniku
- opće kretanje stanovništva
- stopa obrazovanosti

Svi su navedeni parametri izraženi u postotku od prosjeka Republike Hrvatske, isto kao i sam indeks razvijenosti, koji predstavlja postotak razvijenosti pojedine jedinice lokalne i područne (regionalne) samouprave u Republici Hrvatskoj. Postupak izračuna i standardizacije podataka propisan je *Uredbom o indeksu razvijenosti („Narodne novine" broj 63/2010)*, a prema *Odluci o razvrstavanju jedinica lokalne i područne (regionalne) samouprave prema stupnju razvijenosti* („Narodne novine" broj 89/2010) općine i gradovi su svrstani u pet kategorija.

[51] Podaci za pojedine pokazatelje biti će iskazani u odnosu prema najboljem pokazatelju.

2. Indeks ekonomske efikasnosti gradova Republike Hrvatske predstavlja rezultat istraživanja koje je proveo Razvojni forum Zagreb u razdoblju od 2004. do 2009. godine, a kojim je bilo obuhvaćeno ukupno 127 gradova. Efikasnost gradova izračunata je na osnovi pet indikatora uspješnosti poslovanja gospodarstva i to:

- usporediva efikasnost poslovnih sredstava, kao omjer dohotka i poslovnih sredstava,
- izvozna usmjerenost, izražen udjelom izvoza u ukupnim prihodima,
- profitabilnost, kao omjer ostvarenog profita i kapitala,
- proizvodnost rada, kao omjer dohotka i broja zaposlenih,
- investicije u dugotrajnu imovinu, iskazanu udjelom na početku razdoblja.

U cilju utvrđivanja odnosa između odabranih performansi u odnosu na razinu utjecaja DO-a u upravljanju i dobivenih rezultata relativne učinkovitosti u AOMP metodi uvrstit će se dva nediskrecijska ulaza, a rezultati učinkovitosti će se staviti u korelaciju s već navedenim pokazateljima razine ekonomskoga razvoja.

Odabrani će ulazi (***x***) i izlazi (**y**) biti obrađeni Frontier Analyst Banxia Software, *version 4.1.0,* metodom analize omeđivanja podataka u cilju identificiranja gradova s „najboljom praksom" čija će relativna efikasnost definirati granicu efikasnosti prema kojoj će se uspoređivati ostali gradovi. Najbolji će gradovi dobiti 1 (100%), a ostali se nalaze u rasponu od 0 do 1 (0-99.9%).

4.4. Empirijski podaci za analizu učinkovitosti gradova u RH

Vrijednosti opisanih varijabli u prethodnom poglavlju, prikupljene su za četverogodišnje razdoblje koje se poklapa s jednim mandatom lokalne vlasti odnosno DO i prikazane su u *Tablici* 4-1. Za analizu učinkovitosti upravljanja uzet je četverogodišnji prosjek odabranih ulaza i izlaza, a radi međusobne usporedivosti i što realnijega iskazivanja, pokazatelji poreznih i komunalnih prihoda te dohodak su stavljeni u odnosu prema broju stanovnika (X_1, X_2 *i* X_4), a investicije po zaposlenome (Y_3), a ostali su iskazani stopama, udjelima, odnosno prosjekom. Normalizirani numerički pokazatelji ulaza i izlaza (*Tablica 4-2*) iskazuju odnos prema najboljem pokazatelju u skupini, a izračunati su na slijedeći način:

a) Porez i prirez po stanovniku

$$x_n = \frac{vrijednost\ četverogodišnjeg\ prosjeka\ grada\ n}{max.vrijednost\ četverogodišnjeg\ prosjeka} \times 100$$

Tablica 4-1: Izvorni empirijski podaci

GRAD	Broj stanovnika	Godina	*Prosječan broj nezaposlenih*	*Prosječan broj osiguranika HZMO*	*Porez na dohodak i prirez*	*Komunalni doprinos i naknada*	*Stopa nezaposl.*	*Prosječna plaća*	*Investicije*	***ČETVEROGODIŠNJI PROSJEK***						
										Porezni prihodi x_1	*Komunalni prihodi* x_2	*Prosječan broj RAS* x_3	*Dohodak po stanovniku* x_4	*Stopa nezaposlenosti* y_1	*Prosječne plaće* y_2	*Investicijski potencijal* y_3
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
BJELOVAR	41.869	2005.	3.447	17.426	43.784.807,32	15.200.046,02	16,51%	3.041	221.445.497	1.462,23	400,39	21.557	25.692,00	15,17%	3.377,75	14.315,22
		2006.	3.456	18.076	48.672.622,77	16.203.895,07	16,05%	3.315	258.582.821							
		2007.	3.231	18.847	72.949.742,24	16.764.609,74	14,63%	3.454	287.786.569							
		2008.	2.935	18.808	79.480.669,92	18.887.480,47	13,50%	3.701	281.709.968							
DUBROVNIK	43.770	2005.	2.681	18.937	90.154.636,79	57.659.204,00	12,40%	3.953	4.406.526.502	2.575,38	1.710,81	22.554	31.117,00	9,79%	4.340,50	99.048,24
		2006.	2.211	19.243	114.778.400,0	82.650.000,00	10,31%	4.161	909.874.935							
		2007.	2.105	21.192	118.438.020,0	91.613.138,00	9,04%	4.500	1.357.129.343							
		2008.	1.767	22.079	127.527.279,0	67.605.947,00	7,41%	4.748	1.151.990.398							
KARLOVAC	59.395	2005.	5.338	22.214	71.380.063,16	29.203.466,17	19,37%	3.556	335.808.354	1.581,94	560,93	27.729	28.490,00	17,71%	3.781,50	15.352,81
		2006.	5.316	21.861	77.431.482,73	30.231.235,24	19,56%	3.646	326.671.499							
		2007.	4.812	23.569	107.255.744,4	30.915.666,08	16,96%	3.842	461.985.753							
		2008.	4.157	23.649	119.769.060,1	42.915.046,42	14,95%	4.082	277.869.993							
OSIJEK	114.616	2005.	8.921	51.587	136.749.846,2	66.698.820,09	14,74%	3.130	922.212.942	1.603,77	693,12	61.396	28.628,00	12,50%	3.431,75	20.802,61
		2006.	8.136	52.779	147.923.969,8	97.440.547,90	13,36%	3.301	1.002.093.201							
		2007.	7.180	54.861	213.299.761,6	72.882.204,32	11,57%	3.540	1.155.915.460							
		2008.	6.422	55.698	237.297.841,8	80.749.189,82	10,34%	3.756	1.407.884.272							
PULA	58.594	2005.	2.769	30.817	79.665.002,50	28.551.764,17	8,24%	3.686	622.296.620	1.850,97	690,52	34.807	32.380,00	6,16%	3.929,25	19.179,63
		2006.	2.056	31.291	88.766.581,34	38.927.879,23	6,17%	3.832	700.417.976							
		2007.	1.949	34.079	125.974.083,7	45.540.659,46	5,41%	3.923	610.664.317							
		2008.	1.749	34.517	139.418.143,0	48.820.900,35	4,82%	4.276	559.939.954							
RIJEKA	114.043	2005.	8.558	70.326	148.742.212,4	127.018.327,81	10,85%	3.719	1.412.229.863	1.990,74	1.139,82	79.367	33.271,00	9,72%	4.003,50	25.716,22
		2006.	8.323	70.985	194.573.823,2	120.857.725,85	10,49%	3.862	1.818.854.536							
		2007.	7.344	72.266	266.333.134,5	136.734.410,85	9,22%	4.026	2.467.688.814							
		2008.	6.620	73.044	298.469.715,8	135.345.474,61	8,31%	4.407	1.680.982.897							
SAMOBOR	36.206	2005.	1.682	9.484	48.037.070,00	26.944.052,00	15,06%	3.678	226.309.312	2.080,13	970,93	20.200	34.114,00	11,46%	3.960,75	25.431,17
		2006.	1.393	9.901	53.868.625,10	30.816.992,72	12,33%	3.787	230.221.044							
		2007.	1.195	10.756	90.274.724,00	33.835.393,00	10,00%	3.944	325.244.283							
		2008.	1.019	11.070	109.072.293,4	49.018.050,44	8,43%	4.434	269.795.321							
SISAK	52.236	2005.	5.161	19.894	50.896.100,00	58.200.320,00	20,60%	3.294	228.719.229	1.497,67	1.408,32	24.529	29.747,00	18,48%	3.631,00	11.128,29
		2006.	4.762	19.691	60.952.738,00	65.026.592,00	19,47%	3.637	298.659.604							
		2007.	4.279	20.080	95.916.140	89.696.369,00	17,57%	3.511	175.556.480							
		2008.	3.945	20.303	105.163.477,0	81.335.802,00	16,27%	4.082	184.881.058							
SLAVONSKI BROD	64.612	2005.	5.387	23.692	55.229.842,00	13.475.501,00	18,53%	3.054	154.627.984	1.159,99	250,59	32.116	21.172,00	15,55%	3.316,00	9.759,14
		2006.	5.300	24.254	58.770.342,00	14.815.021,00	17,93%	3.254	350.565.333							
		2007.	4.846	29.879	88.312.677,00	19.986.302,00	13,96%	3.468	262.093.552							
		2008.	4.131	30.973	97.484.676,00	16.487.490,00	11,77%	3.488	287.560.156							
SPLIT	188.694	2005.	15.804	80.547	229.498.415,0	136.334.228,17	16,40%	3.573	1.728.795.464	1.710,05	905,74	99.955	29.625,00	14,70%	3.876,25	25.176,89
		2006.	15.565	81.705	247.589.982,0	151.578.107,00	16,00%	3.746	1.941.484.706							
		2007.	14.331	88.228	387.427.882,9	168.947.484,80	13,97%	3.928	2.319.571.108							
		2008.	12.857	90.782	426.185.572,7	226.773.792,57	12,41%	4.258	2.650.072.175							
ŠIBENIK	51.553	2005.	4.685	18.282	40.431.671,73	15.537.177,85	20,40%	3.350	158.042.482	1.312,71	410,05	21.948	27.402,00	14,51%	3.521,50	13.005,83
		2006.	3.105	18.321	55.207.515,91	16.336.031,18	14,49%	3.393	229.914.879							
		2007.	2.713	19.301	84.552.389,97	21.357.974,15	12,32%	3.509	154.662.026							
		2008.	2.317	19.068	90.504.080,00	31.326.220,67	10,83%	3.834	435.058.947							
VARAŽDIN	49.075	2005.	2.598	32.821	75.536.410,35	21.444.694,62	7,34%	3.244	670.226.125	2.122,35	609,97	36.579	34.269,00	5,88%	3.509,25	29.343,53
		2006.	2.252	33.498	82.060.440,91	31.362.212,85	6,30%	3.374	882.178.375							
		2007.	2.016	35.631	125.256.582,6	28.863.871,61	5,36%	3.571	1.203.340.090							
		2008.	1.696	35.804	133.764.598,6	38.065.595,06	4,52%	3.848	1.319.232.347							
VELIKA GORICA	63.517	2005.	2.490	13.691	88.310.971,52	21.024.014,50	15,39%	4.478	1.080.214.266	1.934,03	500,48	16.689	29.905,00	11,75%	4.811,00	57.521,50
		2006.	2.068	14.048	95.726.529,16	26.804.720,93	12,83%	4.654	726.000.777							
		2007.	1.730	15.323	145.693.232,9	40.691.812,91	10,14%	4.879	795.566.172							
		2008.	1.502	15.902	161.645.495,2	38.634.520,72	8,63%	5.233	756.722.842							
VINKOVCI	35.912	2005.	2.924	16.079	29.177.374,0	11.928.551,44	15,39%	2.939	233.052.799	1.054,85	421,39	19.960	23.204,00	13,40%	3.073,50	17.239,33
		2006.	2.713	16.771	30.692.134,8	13.835.898,69	13,92%	2.892	257.128.310							
		2007.	2.617	18.252	42.797.536,6	16.204.324,83	12,54%	3.139	267.804.619							
		2008.	2.405	18.077	48.573.316,4	18.563.703,09	11,74%	3.324	442.140.846							
ZADAR	72.718	2005.	4.849	29.690	85.817.637,43	59.866.953,51	14,04%	3.692	1.082.832.721	1.547,01	880,59	37.231	26.706,00	12,31%	3.968,25	35.961,85
		2006.	4.769	30.769	87.805.606,21	66.246.496,18	13,42%	3.707	1.080.732.328							
		2007.	4.510	34.585	130.894.068,7	81.239.883,29	11,54%	3.809	1.424.268.115							
		2008.	4.068	35.684	145.465.047,3	48.784.694,49	10,23%	4.665	1.108.714.755							

Primjer:

$$x_{Bjelovar} = \frac{1.462,23}{2.575,38} \times 100 = 56,78$$

b) Komunalni prihodi po stanovniku

$$x_n = \frac{vrijednost\ četverogodišnjeg\ prosjeka\ grada\ n}{max.vrijednost\ četverogodišnjeg\ prosjeka} \times 100$$

Primjer:

$$x_{Vinkovci} = \frac{421,39}{1.710,80} \times 100 = 24,63$$

c) Prosječan broj RAS

$$x_n = \frac{vrijednost\ četverogodišnjeg\ prosjeka\ grada\ n}{max.vrijednost\ četverogodišnjeg\ prosjeka} \times 100$$

Primjer:

$$x_{Sisak} = \frac{24.528,75}{99.954,75} \times 100 = 24,54$$

d) Dohodak po stanovniku

$$x_n = \frac{vrijednost\ četverogodišnjeg\ prosjeka\ grada\ n}{max.vrijednost\ četverogodišnjeg\ prosjeka} \times 100$$

Primjer:

$$x_{Zadar} = \frac{26.706,00}{34.269,00} \times 100 = 77,93$$

e) Stopa nezaposlenost

$$x_n = \frac{\min\ vrijednost\ \ četverogodišnjeg\ prosjeka}{vrijednost\ četverogodišnjeg\ prosjeka\ grada\ n} \times 100$$

Primjer:

$$x_{Split} = \frac{5,88}{14,70} \times 100 = 40,01$$

f) Prosječna plaća

$$x_n = \frac{vrijednost\ četverogodišnjeg\ prosjeka\ grada\ n}{max.vrijednost\ četverogodišnjeg\ prosjeka} \times 100$$

Primjer:

$$x_{Varaždin} = \frac{3.509,25}{4.811,00} \times 100 = 72,94$$

g) Investicijski potencijal

$$x_n = \frac{vrijednost\ četverogodišnjeg\ prosjeka\ grada\ n}{max.vrijednost\ četverogodišnjeg\ prosjeka} \times 100$$

Primjer:

$$x_{Samobor} = \frac{25.431,17}{99.048,24} \times 100 = 25,68$$

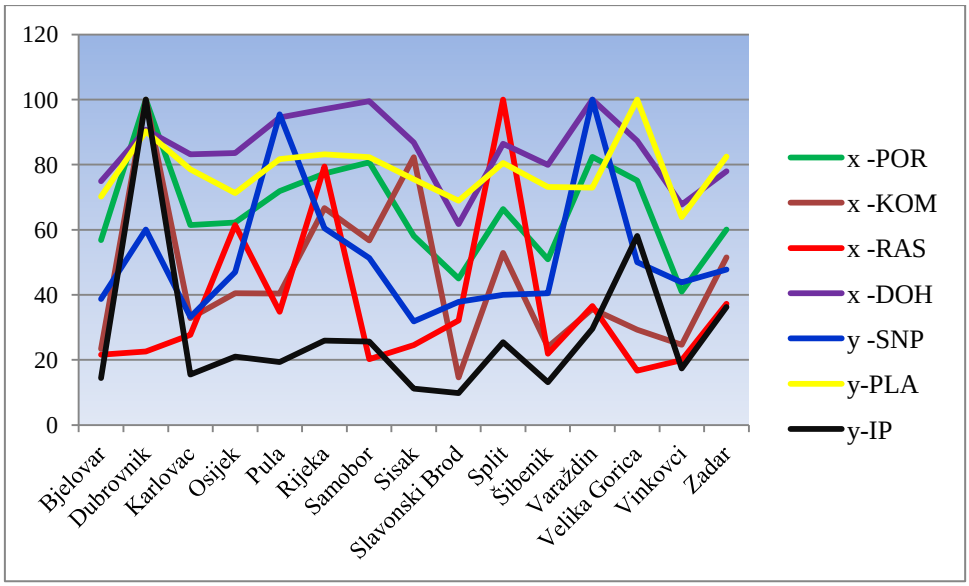
Tablica 4-2*:* Normalizirani podaci ulaza i izlaza

GRAD	Porez i prirez po stanovniku	Komunalni prihodi po stanovniku	Prosječan broj RAS	Dohodak po stanovniku	Stopa nezaposlen.	Prosječna plaća	Investicijski potencijal
	X_1	X_2	X_3	X_4	Y_1	Y_2	Y_3
Bjelovar	56,78	23,4	21,57	74,97	38,75	70,21	14,45
Dubrovnik	100,00	100,00	22,56	90,80	60,06	90,22	100,00
Karlovac	61,43	32,79	27,74	83,14	33,20	78,60	15,50
Osijek	62,27	40,51	61,42	83,54	47,03	71,33	21,00
Pula	71,87	40,36	34,82	94,49	95,45	81,67	19,36
Rijeka	77,30	66,62	79,40	97,09	60,51	83,22	25,96
Samobor	80,77	56,75	20,21	99,55	51,33	82,33	25,68
Sisak	58,15	82,32	24,54	86,80	31,82	75,47	11,24
Slavonski Brod	45,04	14,65	32,13	61,78	37,82	68,93	9,85
Split	66,40	52,94	100,00	86,45	40,01	80,57	25,42
Šibenik	50,97	23,97	21,96	79,96	40,52	73,20	13,13
Varaždin	82,41	35,65	36,60	100,00	100,00	72,94	29,63
Velika Gorica	75,10	29,25	16,70	87,27	50,05	100,00	58,07
Vinkovci	40,96	24,63	19,97	67,71	43,89	63,88	17,40
Zadar	60,07	51,47	37,25	77,93	47,78	82,48	36,31

Izvor: obrada autora

Iz grafičkog prikaza normaliziranih podataka odabranih performansi gradova (*Slika 4-3*) mogu se izvesti zaključci o evidentnoj dominaciji Dubrovnika koji imaj najveće vrijednosti u četiri od ukupno sedam pokazatelja. S druge strane, uspoređujući najniže vrijednosti normaliziranih podataka, najveću frekvenciju pokazuje Slavonski Brod s tri vrijednosti, a slijede Vinkovci i Sisak s dvije vrijednosti.

Nakon provedene analize učinkovitosti metodom omeđivanja podataka bit će moguće utvrditi zavisnost iznesenih zapažanja s rezultatima relativne učinkovitosti.



Slika 4-3: Prikaz normaliziranih pokazatelja

Radi lakšeg praćenja podataka na slikama i u tablicama uz oznake ulaza (x) i izlaza (y) dodane su skraćeni nazivi varijabli kako slijedi:

- x_1 – POR => porez i prirez na dohodak (*per capita*)
- x_2 – KOM => komunalni doprinos i druge naknade (*per capita)*
- x_3 – RAS => prosječan broj radno aktivnog stanovništva
- x_4 – DOH => dohodak po stanovniku
- y_1 – SNP => stopa nezaposlenosti
- y_2 – PLA => prosječne plaće
- y_3 – IP => investicijski potencijal (investicije u gospodarstvu po zaposlenom)

U *Tablici 4-3* je prikazana deskriptivna statistika ulaza i izlaza uključenih u analizu učinkovitosti upravljanja gradovima u Republici Hrvatskoj.

Za navedene varijable prikazane su srednje vrijednosti, standardna devijacija, maksimalna i minimalna vrijednost te ukupne vrijednosti u nominalnom iznosu. Varijable x_1-porez i prirez na dohodak po stanovniku, x_2 – komunalni doprinos i druge naknade po stanovniku, x_3 – *prosječan broj RAS*, x_4 – dohodak po stanovniku, y_2 – prosječne plaće i y_3 – investicije u gospodarstvu po zaposlenom iskazane su u novčanom iznosu (kuna), a varijabla y_1 – stopa nezaposlenosti u postotnom iznosu.

Tablica 4-3: Deskriptivna statistika ulaza i izlaza uključenih u model AOMP-a

	Ulazi				Izlazi		
	X_1- *POR*	X_2- *KOM*	X_3- *RAS*	X_4-*DOH*	Y_1- SNP	Y_2- PLA	Y_3- IP
srednja vrijednost	1.698,79	770,24	37.107	29.048,13	12,60	3.768,78	27.932,15
standardna devijacija	401,41	406,38	24.323,00	3815,61	0,0367	498,69	23051,35
maksimum	2.575,38	1.710,81	99.955	34.269	18,48	5.233,00	99.048,24
minimum	1.052,87	250,59	16.688	21.172	5,88	2.892,00	9.759,14
ukupna vrijednost	25.481,84	11.553,65	556.613,75	435.722	189,07	226.127,00	418.982,27

Izvor: obrada autora

Omjer između najvećih i najmanjih vrijednosti koje opisuju izabrane ulaze i izlaze su sljedeće:

- Porez i prirez po stanovniku 1 : 2,44
- Komunalni prihodi po stanovniku 1 : 6,83
- Prosječan broj RAS 1: 12
- Dohodak po stanovniku 1 : 1,61
- Stopa nezaposlenosti 1 : 3,14
- Prosječna plaća 1 : 1,8
- Investicije po zaposlenom 1 : 10,15

Iskazani omjeri upućuju na najveće razlike u područjima prosječnog broja RAS i investicija po zaposlenom u gospodarskom sektoru, a najveću ujednačenost u prosječnim plaćama, dohotku po stanovniku i stopi nezaposlenosti. S obzirom na to da je većina pokazatelja izražena po glavi stanovnika, odnosno po zaposlenom, omjeri između minimalnih i maksimalnih vrijednosti ukazuju da su resursi kojima upravljaju lokalne vlasti različiti, a samo istraživanje će pokazati u kojoj mjeri koreliraju s prosječnom učinkovitošću.

4.5. Statistička verifikacija podataka

Za korištenje AOMP metode u analizi učinkovitosti upravljanja hrvatskim gradovima uz identifikaciju zajedničkih varijabli za sve DO koji se međusobno razlikuju prema razini resursa i aktivnostima unutar procesa transformacije, potrebno je utvrditi povezanost ulaza i izlaza (eng. *Isotonicity*). Utvrđivanje razine međusobne povezanosti odabranih pokazatelja za analizu omeđivanja podataka prema Šporčiću (2007.) potrebna je zbog testiranja pretpostavke o međusobnoj neovisnosti odabranih varijabli ulaza, odnosno izlaza i razini povezanosti između

varijabli ulaza i izlaza. Kao što je već prije napomenuto, bitna pretpostavka AOMP analize je da pozitivna promjena ulaza uvijek rezultira pozitivnom promjenom izlaza.

Premda je za opis aktivnosti lokanih vlasti uzet ograničen broj pokazatelja, njihova vjerodostojnost i povezanost utvrđena je Pearsonovim koeficijentom korelacije, koji je prikazan u *Tablici 4-4.* Za izračun je korištena funkcija CORREL u Microsoft Excel programu koja koeficijent korelacije računa iz srednjih vrijednosti određenih skupova podataka (*x,y*) čiju povezanost testiramo prema sljedećoj formuli:

$$Korelacija\ (x,y) = \frac{\sum(x-\bar{y})(y-\bar{y})}{\sqrt{\sum(x-\bar{x})^2 \sum(y-\bar{y})^2}}$$

Sjenčanjem izračunatih koeficijenata korelacije u *Tablici 4-4* (Petz, 1997) grupirana je povezanost[52] odabranih performansi.

Tablica 4-4: Matrica koeficijenata korelacije ulaza i izlaza

I/O	X_1- *POR*	X_2- *KOM*	X_3- *RAS*	X_4-*DOH*	Y_1- SNP	Y_2- PLA	Y_3- IP
X_1- *POR*	1,00						
X_2- *KOM*	0,65	1,00					
X_3- *DOB*	0,18	0,33	1,00				
X_4-*DOH*	0,82	0,53	0,20	1,00			
Y_1- SNP	0,56	0,07	0,21	0,61	1,00		
Y_2- PLA	0,70	0,44	0,68	0,52	0,18	1,00	
Y_3- IP	0,75	0,57	0,26	0,31	0,23	0,70	1,00

Izvor: obrada autora

Podaci iz prikazane matrice koeficijenata korelacije pokazuju pozitivnu korelaciju za sve uključene varijable. Posebno je važno analizirati korelaciju između ulaza i izlaza koji će se koristiti za izračun relativne učinkovitosti.

a) *diskrecijski ulazi*

   x_1 - *porez i prirez po stanovniku* pokazuje pozitivnu korelaciju sa svim varijablama izlaza pri čemu je visoka povezanost utvrđena između prosječnih plaća (0,70) i investicijskog potencijala (0,75), dok značajnu povezanost pokazuju porezni prihodi s stopom nezaposlenosti (0,56).

[52] Gruba aproksimacija dobivenih koeficijenata korelacije prema Petzu, 1997. koeficijent korelacije od 0,00 do ± 0,20 znači nikakvu ili neznatnu povezanost, od 0,20 do ± 0,40 znači laku povezanost, r od ± 0,40 do ± 0,70 znači stvarnu značajnu povezanost, a od ± 0,70 do ± 1,00 znači visoku ili vrlo visoku povezanost.

x_2 –*komunalni prihodi po stanovniku* pokazuju značajnu povezanost s varijablama prosječnih plaća (0,44) i investicijskim potencijalom (0,57), dok sa stopom nezaposlenosti ne pokazuju nikakvu povezanost (0,07).

b) *nediskrecijski ulazi*

x_3 - *prosječan broj RAS* pokazuje stvarnu povezanost sa prosječnim plaćama (0,68) i laku povezanost sa stopom nezaposlenosti (0,21) i investicijskim potencijalom (0,26).

x_4 –*dohodak po stanovniku* pokazuje značajnu povezanost sa stopom nezaposlenosti (0,61) i prosječnim plaćama (0,52) i laku povezanost s investicijskim potencijalom (0,31).

S obzirom na utvrđenu korelaciju između ulaza i izlaza, analiza učinkovitosti prema odabranim varijablama, koja slijedi, dat će vjerodostojne rezultate.

4.6. Rezultati analize relativne učinkovitosti upravljanja hrvatskim gradovima

Analiza relativne učinkovitosti hrvatskih gradova obavljena je na osnovi podataka iz *Tablice 4-2* uz pomoć Frontier Analyst Banxia softvera, koristeći prije navedene modele CCR-izlazno usmjeren (IU CCR) i BCC - izlazno usmjeren model (IU BCC). U toj analizi neće se ograničavati težinski koeficijenti pojedinih ulaza i izlaza iako softver to omogućuje. Osnovni model AOMP-a omogućuje potpunu fleksibilnost u izboru težina (kontribucija) ulaza i izlaza koji omogućuju svakoj jedinici DO-a da postigne maksimalnu učinkovitost prema razini njezinih pokazatelja. Dakle svakomu gradu koji je obuhvaćen analizom, bit će određena takva ulazno-izlazna orijentacija koja će iskazati njezinu najveću učinkovitost uz ograničenje „odozgo“ koje definira gornju granicu ≤ 1. Na ovaj se način izbjegava još jedna mogućnost uključivanja subjektivnosti u analizu koja bi mogla uzrokovati dodjelu neodgovarajućih težina određenim pokazateljima. U sljedećem su poglavlju iskazani rezultati na osnovi diskrecijskih ulaza, kao osnovno istraživanje učinkovitosti upravljanja lokalnom samoupravom u kojem će se odraziti utjecaj kompetentnosti političkoga menadžmenta koji obavlja ulogu DO-a.

4.6.1. Relativna učinkovitost gradova

Izračun relativne učinkovitosti upravljanja hrvatskim gradovima obavljen je na osnovi pet performansi, od kojih dvije predstavljaju resurse (ulazi) kojima politički menadžment ostvaruje rezultate iskazane kroz preostala tri pokazatelja (izlazi). U ovu su analizu uključeni resursi na koje DO imaju diskrecijski utjecaj u njihovu upravljanju, kao osnova za ocjenu utjecaja lokalnih vlasti na ekonomske pokazatelje razvoja.

U *Tablici 4-5*. su prikazani rezultati ocjene relativne učinkovitosti upravljanja hrvatskim gradovima prema oba modela; CCR koji pretpostavljaju konstantne prinose i računaju ukupnu učinkovitost i BCC modelu koji pretpostavlja varijabilne prinose s obzirom na opseg djelovanja, što će omogućiti analizu u širem rasponu. Diferencija rezultata učinkovitosti između tih dvaju modela omogućit će utvrđivanje odnosa između opsega poslovanja i učinkovitosti.

Tablica 4-5: Rezultati analize učinkovitosti upravljanja hrvatskim gradovima

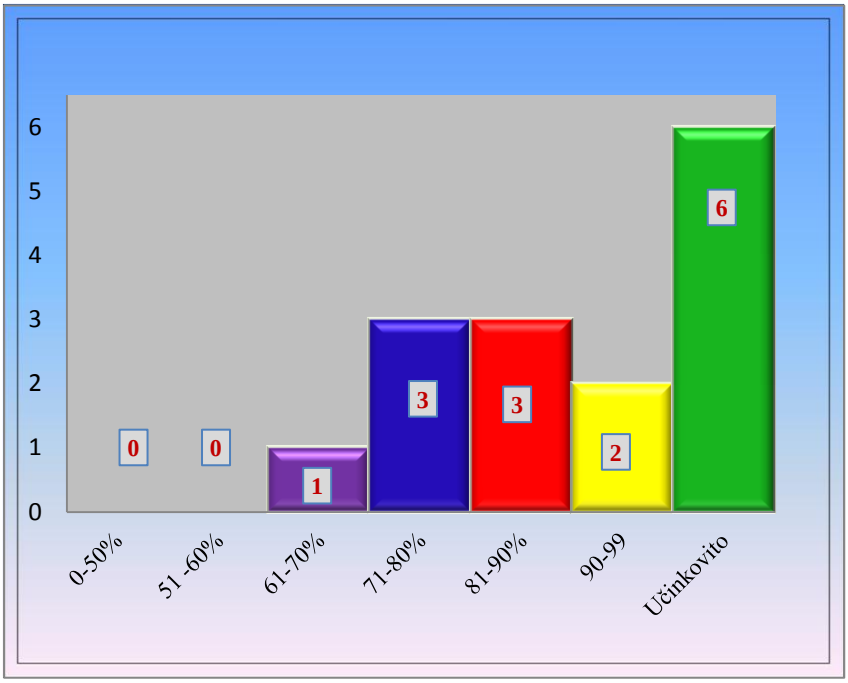
R.br.	DO	Relativna učinkovitost			
		CCR model	Frekvencija uspješnih DO	BCC model	Frekvencija uspješnih DO
1.	Bjelovar	80,97%		81,75	
2.	Dubrovnik	100,00%	1	100,00%	0
3.	Karlovac	82,42%		88,55%	
4.	Osijek	74,35%		77,91%	
5.	Pula	100,00%	1	100,00%	3
6.	Rijeka	73,61%		81,10%	
7.	Samobor	66,79%		74,11%	
8.	Sisak	83,22%		88,34%	
9.	Slavonski Brod	100,00%	3	100,00%	6
10.	Split	79,67%		84,79%	
11.	Šibenik	92,91%		96,87%	
12.	Varaždin	100,00%	0	100,00%	0
13.	Velika Gorica	100,00%	5	100,00%	9
14.	Vinkovci	100,00%	9	100,00%	6
15.	Zadar	96,25%		97,45%	

Izvor: obrada autora

Prosječna relativna učinkovitost prema CCR modelu iznosi 87,67% što znači da prosječno učinkovit grad mora postizati iste rezultate koristeći 87,68% resursa (UU CCR), odnosno 14%[53] bolje rezultate s istim resursima (IU CCR). BCC model, uzimajući u obzir varijabilne prinose, iskazuje višu relativnu učinkovitost koja za promatrane jedinice iznosi 91,39%, što znači da prosječan grad treba koristiti 91,39% trenutačno dostupnih količina resursa za produkciju iste količine postignutih rezultata, ako želi postići granicu učinkovitosti. Drugim riječima, ako želi učiniti svoje poslovanje učinkovitim, prosječni grad treba proizvesti 9,42% više izlaza s istom količinom resursa (eng. *inputa*). Distribucija rezultata relativne učinkovitosti pokazuje standardnu

[53] $14{,}06\% = \frac{1-0{,}8767}{0{,}8767}\ 100$

devijaciju za CCR model 0,118, odnosno 0,0945 za BCC model, a distribuciju učinkovitosti, prema CCR modelu, prikazuje *Slika 4-4.*



Slika 4-4: Distribucija učinkovitosti DO-a prema CCR modelu

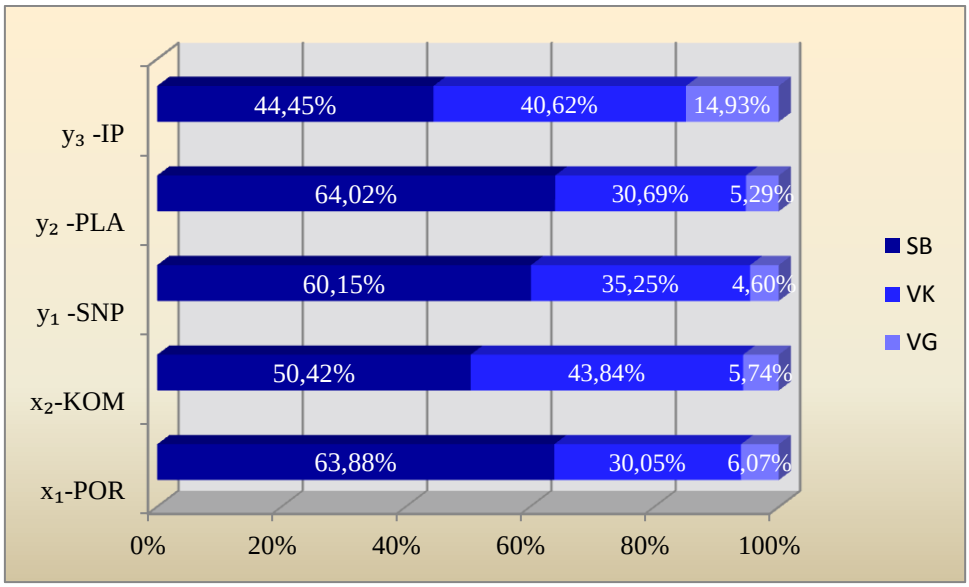
Uzmemo li u razmatranje relativnu učinkovitost prema oba modela, od cijele populacije (15) velikih gradova u Republici Hrvatskoj šest gradova je uspješno i oni definiraju granicu učinkovitosti upravljanja. Budući da je 40% gradova uspješno, njihovi se rezultati pojavljuju u skupu referentnih gradova kao uzorni gradovi (eng. *benchmarking*) neučinkovitim gradovima (*Tablica 4-6*). Referentni skup čine učinkoviti DO koji bi sa težinskim koeficijentima neučinkovitih gradova ostali učinkoviti. Dakle u referentni skup ulaze učinkoviti gradovi čija ulazno izlazna usmjerenost najsličnija onoj koju ima neučinkoviti grad, ali ih postignuti učinci sa zadanim resursima čine učinkovitima. Za svaki neučinkoviti grad određen je najmanje jedan referentni DO koji predstavlja uzornu praksu. U praksi je važno utvrditi koji od ponuđenih referentnih uzora odabrati kao uzor i primjer dobre prakse u postizanju relativne učinkovitosti za neučinkovite gradove. Uz referentni grad za svaki neučinkoviti grad istaknut je koeficijent koji se odnosi na vektor optimalnih vrijednosti varijabli koji projicira indikatore efikasnosti na granicu efikasnosti. Naime, projekcija na granicu učinkovitosti za svaki neučinkoviti DO se izražava linearnom kombinacijom varijabli ulaza i izlaza DO iz njegovog referentnoga skupa, a udjeli u formiranju te projekcije na granicu učinkovitosti izražavaju se koeficijentom. Stoga se u praksi između ponuđenih uzornih DO bira onaj čiji je koeficijent najveći jer je on imao najveći utjecaj u formiranju projekcije na granicu učinkovitosti.

Tablica 4-6: Skup referentnih gradova prema CCR modelu

R. br.	Neučinkoviti DO	Referentni skup gradova	
		Uzorni grad	koeficijent*
1.	Bjelovar	Slavonski Brod	0,65
		Vinkovci	0,34
		Velika Gorica	0,04
2.	Karlovac	Vinkovci	0,93
		Slavonski Brod	0,28
3.	Osijek	Vinkovci	1,04
		Velika Gorica	0,05
4.	Rijeka	Vinkovci	1,13
		Pula	0,08
		Dubrovnik	0,05
5.	Samobor	Vinkovci	1,12
		Velika Gorica	0,11
6.	Sisak	Vinkovci	1,18
7.	Split	Vinkovci	1,08
		Velika Gorica	0,11
8.	Šibenik	Vinkovci	0,61
		Slavonski Brod	0,50
9.	Zadar	Vinkovci	0,59
		Velika Gorica	0,45

Izvor: obrada autora

Radi lakšeg razumijevanja prikazan je primjer neučinkovitog grada Bjelovara čija je relativna učinkovitost prema CCR modelu 80,97%. U projekciji na granicu učinkovitosti sudjelovali su gradovi Slavonski Brod, Velika Gorica i Vinkovci sa udjelima koji su prikazani na *Slici 4-5*.

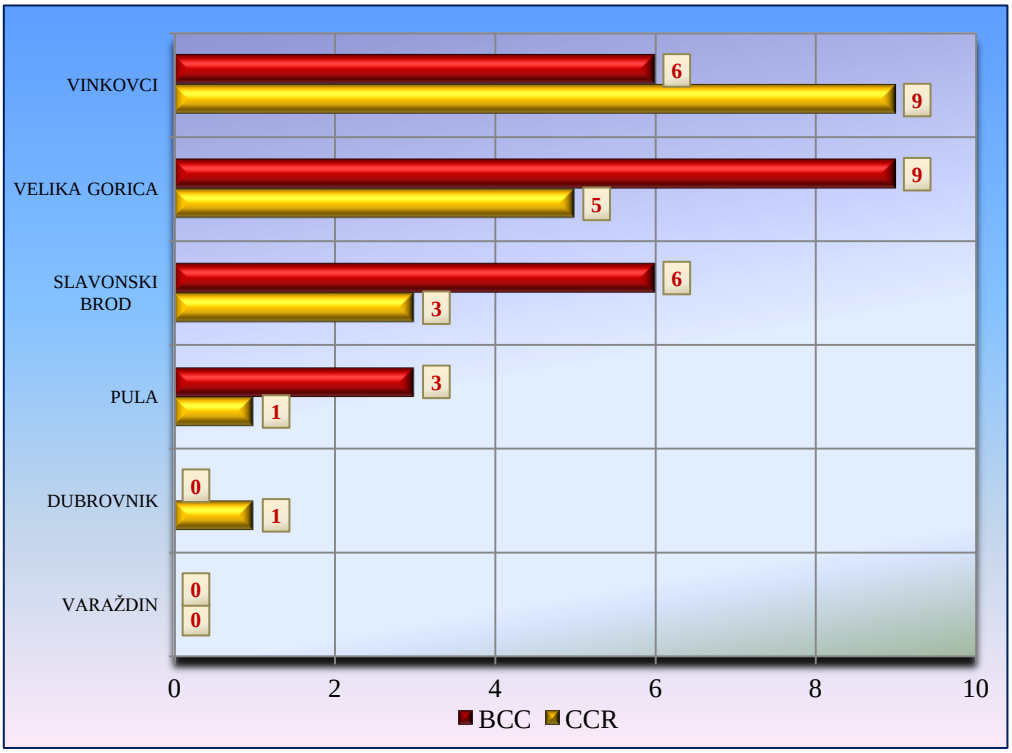


Slika 4-5: Kontribucija u referentnom skupu

Kao što je vidljivo, udio Slavonskog Broda je najveći u svim varijablama, stoga je i njegov koeficijent najveći pa će grad Bjelovar iz referentnoga skupa između Slavonskoga Broda (0,65), Vinkovaca (0,34) i Velike Gorice (0,04) odabrati Slavonski Brod.

Činjenica da je broj učinkovitih jedinica identičan u oba modela, ukazuje na to da nema utjecaja obima poslovanja na rezultate i da su rezultati dobiveni CCR modelom vjerodostojni, a s obzirom na to da su oni restriktivniji, za daljnju će se analizu koristiti samo CCR učinkovitost.

Frekvencija pojavljivanja u setu referentnih gradova za relativno neučinkovite gradove može se interpretirati kao dodatni argument učinkovitosti. Što je frekvencija pojavljivanja relativno učinkovitoga grada u referentnome skupu relativno neučinkovitih gradova veća, to je veća vjerojatnost da je riječ o primjeru dobre prakse koji bi trebali slijediti neučinkoviti gradovi. Prema prikazanim rezultatima na S4-6, Vinkovci predstavljaju najučinkovitiji grad prema CCR modelu, s obzirom da predstavlja referencu za ukupno devet neučinkovitih gradova. Slijedi ga Velika Gorica (5), Slavonski Brod (3) te Pula i Dubrovnik (1) dok je grad Varaždin referentan samo u svojem skupu. Prema BCC modelu Velika Gorica predstavlja primjer najbolje prakse jer se najčešće pojavljuje u referentnome skupu (9 puta), slijede Vinkovci i Slavonski Brod (6 puta) i na kraju Pula, dok su gradovi Varaždin i Dubrovnik referentni samo u svojem skupu.



Slika 4-6 : Frekvencija pojavljivanja učinkovitih DO-a

Među neučinkovitim gradovima, prema oba modela, najnižu razinu učinkovitosti pokazuje Samobor (66,8%-74,1%), zatim Rijeka (73,61%-81,1%), Osijek (74,35%-77,91), Karlovac (82,42%-88,55%), Sisak (83,22%-88,34%), Split (79,67%-84,79%), Bjelovar (80,97%-81,75%), Šibenik (92,91%-96,87%) i Zadar (96,25%-97,45%).

Analiza omeđivanja podataka je metoda koja dodjeljuje svakomu ulazu i izlazu najpovoljniju težinu (kontribucija). Pojam najpovoljnijih težina podrazumijeva da je rezultirajući omjer ulaza i izlaza za svakoga DO-a maksimaliziran u odnosu na sve ostale iz odabranoga skupa (Rabar, 2011.) Prikazana ulazno/izlazna orijentacija (kontribucija) u *Tablici 4-7* pokazuje utjecaj određenoga pokazatelja na postignuti rezultat u analizi.

U domeni ulaza je parametar *porez i prirez po stanovniku* dominantno utjecao na rezultate učinkovitosti u odnosu na *komunalne prihode po stanovniku* (4:1) dok je u domeni izlaza dominirala *prosječna plaća* nad *investicijama po zaposlenom* i *stopom nezaposlenosti* (3:1:1).

Tablica 4-7: Ulazno – izlazna orijentacija (kontribucija)

R.br.	DO	Input/output kontribucija				
		X_1 - POR	X_2 - KOM	Y_1 - SNP	Y_2 - PLA	Y_3 - IP
1.	Bjelovar	0,9	0,1	0	0,92	0,08
2.	Dubrovnik	1	0	0	0	1
3.	Karlovac	0,96	0,04	0	1	0
4.	Osijek	1	0	0	0,84	0,16
5.	Pula	1	0	0,83	0,17	0
6.	Rijeka	1	0	0,53	0,21	0,26
7.	Samobor	1	0	0	0,83	0,17
8.	Sisak	1	0	0	1	0
9.	Slavonski Brod	0	1	0,41	0,59	0
10.	Split	1	0	0	0,83	0,17
11.	Šibenik	0,97	0,03	0	1	0
12.	Varaždin	0,2	0,8	0,86	0	0,14
13.	Velika Gorica	0	1	0	0,13	0,87
14.	Vinkovci	1	0	0,3	0,61	0,09
15.	Zadar	1	0	0	0,78	0,22
Ukupno:		12,03	2,97	2,93	8,91	3,16

Izvor: obrada autora

S obzirom na to da se reference za neučinkovite gradove određuju iz skupa učinkovitih gradova koji bi s njihovom ulazno-izlaznom orijentacijom postigli granicu učinkovitosti, visoku frekvenciju u gradova Vinkovaca i Velike Gorice u skupu referentnih gradova treba uzeti kao dodatnu mjeru uspješnosti jer bi s težinskim udjelima velikog broja neučinkovitih DO zadržali svoju relativnu učinkovitost. Iako bi se iz podataka u Tablici 4-7 moglo zaključiti da su neki od ključnih indikatora

potpuno isključeni, potrebno je napomenuti da model AOMP-a ne dopušta potpuno zanemarivanje jednoga indikatora jer težinske vrijednosti pojedinoga pokazatelja moraju zadovoljiti uvjet $u_r (v_r) \geq \varepsilon$[54].

Grad Varaždin nije ne predstavlja uzor ni jednom neučinkovitom gradu što znači da samo sa svojom ulazno izlaznom orijentacijom postiže granicu učinkovitosti, ali s težinskim udjelima ni jednog učinkovitog grada ne bi više bio učinkovit.

4.6.2. Izvori neučinkovitosti i projekcija na granicu učinkovitosti

Premda dobiveni rezultati relativne učinkovitosti upravljanja hrvatskim gradovima ne pokazuju ovisnost o opsegu poslovanja, za projekciju neučinkovitih DO-a na granicu učinkovitosti odabran je CCR model usmjeren na rezultate. Izbor modela usmjerenoga na postizanje što boljih rezultata (IU CCR) s istom razinom raspoloživih resursa odredio je i putanju projekcije neučinkovitih gradova na granicu efikasnosti.

U *Tablici 4-8* izneseni su sumarni empirijski podaci pojedinih ulaza i izlaza, njihova ciljana vrijednost i postotak povećanja – smanjenja koji je potreban za postizanje razine učinkovitosti. Usporedbom empirijskih pokazatelja i njihovih projiciranih vrijednosti moguće je identificirati izvore neučinkovitosti i njihov udio u rezultatu. Svi učinkoviti gradovi, u svim identificiranim pokazateljima, imaju izjednačene empirijske i projicirane vrijednosti ulaza i izlaza, a za neučinkovite DO je iskazana projekcija na granicu učinkovitosti, a time i izvori neučinkovitosti.

Najveći izvor neučinkovitosti pokazuje izlaz Y_1 - *stopa nezaposlenosti*, koju je potrebno korigirati za prosječno 48,47%, a predstavlja najznačajniji izvor neučinkovitosti za ukupno šest neučinkovitih gradova (Bjelovar, Karlovac, Osijek, Samobor, Split i Zadar). Utjecaj izlaza Y_3- *Investicije po zaposlenom* na neučinkovitost gradova je također značajan (40,89%), a predstavlja glavni izvor neučinkovitosti za dva grada (Sisak i Šibenik). Izlaz Y_2 - *Prosječne plaće* imaju gotovo upola manji utjecaj na neučinkovitost gradova, a za projekciju neučinkovitih gradova na granicu učinkovitosti potrebno je prosječno povećanje toga pokazatelja za 24,68%. Uz projekciju izlaza na efikasnu granicu, za šest neučinkovitih gradova, potrebno je istovremeno smanjenje ulaza X_2 *Komunalni prihodi* za prosječno 20,73%. Veći utjecaj izlaza na neučinkovitost od ulaza unaprijed je određena izborom modela koji je usmjeren na izlaze, odnosno rezultate.

[54] ε – mala pozitivna vrijednost koja sprječava potpuno zanemarivanje utjecaja pojedinoga indikatora na rezultate učinkovitosti

Tablica 4-8: Projekcija na granicu uspješnosti korekcijom parametara prema IU CCR modelu

	GRAD	CILJANA EFIKASNOST INPUTA						CILJANA EFIKASNOST OUTPUTA								
		Porez i prirez/st			Komunalni prihodi/st			Stopa nezaposlenosti			Prosječne plaće			Investicije po zaposlenom		
		aktualno	ciljano	povećanje/ smanjenje	aktualno	ciljano	povećanje/ smanjenje	aktualno	ciljano	povećanje/ smanjenje	aktualno	ciljano	povećanje/ smanjenje	aktualno	ciljano	povećanje/ smanjenje
1	BJELOVAR	56,78	**56,78**	0,00%	23,40	**23,40**	0,00%	37,75	**50,74**	34,42%	70,21	**86,71**	23,50%	14,45	**17,85**	23,50%
2	DUBROVNIK	100	100	0,00%	100	100	0,00%	60,22	**60,22**	0,00%	90,22	**90,22**	0,00%	100	**100**	0,00%
3	KARLOVAC	61,43	**61,43**	0,00%	32,79	**32,79**	0,00%	32,53	**61,29**	88,41%	78,60	**95,37**	21,33%	15,50	**23,00**	48,37%
4	OSIJEK	62,27	**62,27**	0,00%	40,51	**36,35**	-10,26%	46,36	**63,37**	36,69%	71,33	**95,94**	34,50%	21,00	**28,25**	34,50%
5	PULA	71,87	**71,78**	0,00%	40,36	**40,36**	0,00%	96,15	**96,15**	0,00%	81,67	**81,67**	0,00%	19,36	**19,36**	0,00%
6	RIJEKA	77,30	**77,30**	0,00%	66,62	**48,70**	-26,90%	59,24	**80,48**	35,85%	83,22	**113,06**	35,85%	25,96	**35,27**	35,85%
7	SAMOBOR	80,77	**80,77**	0,00%	56,75	**46,05**	-18,85%	52,10	**80,27**	54,07%	82,33	**123,26**	49,71%	25,68	**38,45**	49,71%
8	SISAK	58,15	**58,15**	0,00%	82,32	**34,97**	-57,52%	31,06	**60,96**	96,27%	75,47	**90,69**	20,17%	11,24	**24,70**	119,77%
9	SLAVONSKI BROD	45,04	**45,04**	0,00%	14,65	**14,65**	0,00%	37,90	**37,90**	0,00%	68,93	**68,93**	0,00%	9,85	**9,85**	0,00%
10	SPLIT	66,40	**66,40**	0,00%	52,94	**37,68**	-28,83%	39,22	**65,67**	67,44%	80,57	**101,13**	25,52%	25,42	**31,91**	25,52%
11	ŠIBENIK	50,97	**50,97**	0,00%	23,97	**23,97**	0,00%	41,48	**48,43**	16,75%	73,20	**78,79**	7,63%	13,13	**16,67**	26,93%
12	VARAŽDIN	82,41	**82,41**	0,00%	35,65	**35,65**	0,00%	100,00	**100,00**	0,00%	72,94	**72,94**	0,00%	29,63	**29,63**	0,00%
13	VELIKA GORICA	75,10	**75,10**	0,00%	29,25	**29,25**	0,00%	50,86	**50,86**	0,00%	100,00	**100,00**	0,00%	58,07	**58,07**	0,00%
14	VINKOVCI	40,96	**40,96**	0,00%	24,63	**24,63**	0,00%	42,94	**42,94**	0,00%	63,88	**63,88**	0,00%	17,40	**17,40**	0,00%
15	ZADAR	60,07	**60,07**	0,00%	51,47	**28,70**	-44,24%	46,98	**49,97**	6,37%	82,48	**85,69**	3,90%	36,31	**37,73**	3,90%
Prosječne vrijednosti poboljšanja performansi neučinkovitih gradova na projiciranu razinu				0,00%	----------		- 20,73%	----------		48,47%	----------		24,68%	----------		40,89%

Izvor: obrada autora

Dakle da bi neučinkoviti gradovi postigli granicu učinkovitosti moraju poduzimati aktivnosti koje će utjecati na smanjenje stope nezaposlenosti, poticati gospodarske investicije i utjecati na kvalitativne promjene gospodarske strukture privlačenjem djelatnosti koje mogu osigurati višu razinu ostvarivanja dohotka zaposlenima.

Sumiraju li se ukupni postotci projekcija na granicu učinkovitosti za neučinkovite gradove dobije se slika ukupnih promjena koje moraju pojedini gradovi učiniti za postizanje učinkovitosti upravljanja. Prema tomu pokazatelju najznačajnije promjene mora poduzeti Sisak, koji mora ukupno poboljšati sve ulaze i izlaze za gotovo 300%, zatim Samobor za 172%, Karlovac 158%, Split za 147%, Rijeka za 134%, Osijek 116%, Bjelovar za 81%, Zadar 58% i Šibenik 51%.

Za postizanje granice učinkovitosti neučinkovitih gradova promjenom ključnih pokazatelja na razinu projiciranih vrijednosti, gradovi će koristiti primjere dobre prakse iz domene referentnih gradova u svojem referentnom skupu. S obzirom na to da su se neučinkoviti gradovi uspoređivali s gradovima koji imaju optimalan odnos težina ulaza i izlaza (izlazno-ulazna orijentacija), oni ujedno predstavljaju najrealniji ostvarivi uzor koji neučinkoviti gradovi mogu postići, jer su sa svojim optimalnim težinama referenci učinkoviti. Dakle jedinice iz referentne grupe neučinkovitih gradova imaju istu ulazno-izlaznu orijentaciju kao i oni sami, ali postižu veću učinkovitost. Razlike ulazno-izlaznih razina neučinkovitih jedinica u odnosu na razine njoj referentne jedinice, ukazuje na izvore njezine neučinkovitosti i pogrešnoga upravljanja javnim resursima. Stoga su gradovi koji imaju sličnu ulazno-izlaznu orijentaciju kao i pojedini neučinkoviti grad uzeti kao primjeri iz čije prakse upravljanja treba učiti jer predstavljaju najrealniji ostvarivi uzor koji neučinkoviti gradovi mogu postići.

Osim mogućnosti mjerenja i uspoređivanja s najboljima iz usporedivog okruženja (benchmarking) model ukazuje na izvore i iznose neučinkovitosti, kao iznimno vrijedan podatak na osnovi kojega politički menadžment neučinkovitih gradova može postaviti ciljeve koje mora doseći i utvrditi aktivnosti koje će rezultirati postizanjem zadanih ciljeva. U sklopu te analize bit će ponuđeni i odgovori na pitanje što promijeniti i u kojoj mjeri da bi postali učinkoviti.

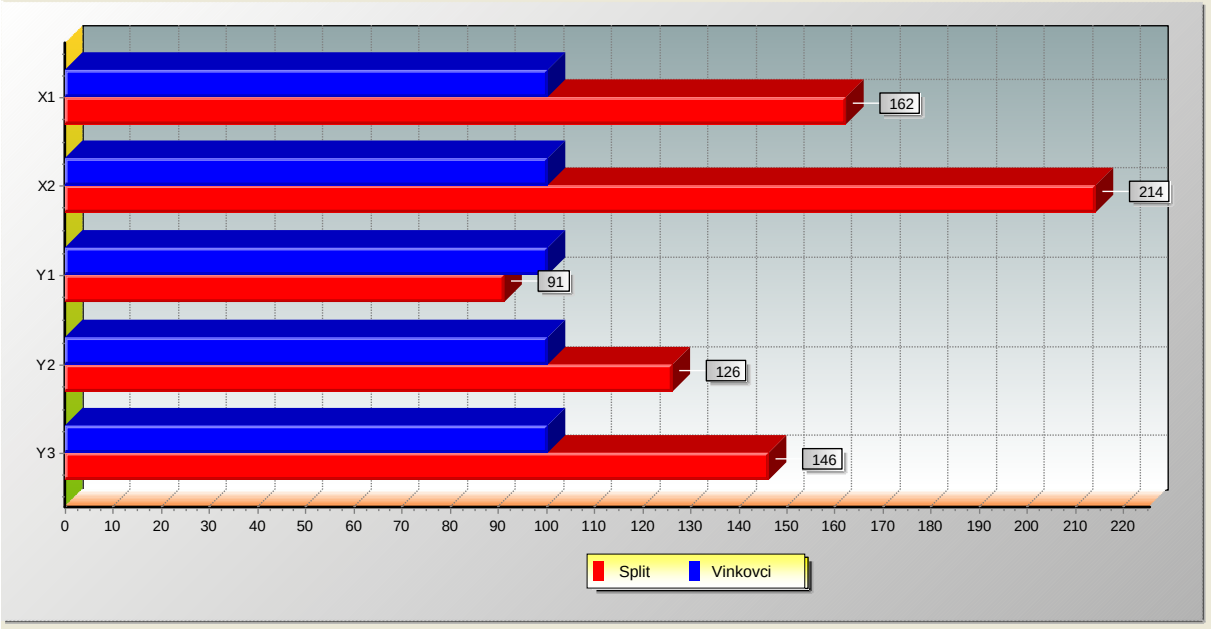
Tumačenje rezultata analize –korisnički pristup

U nastojanju da se analiza omeđivanja podataka prikaže kao funkcijski alat, koji nudi raspon informacija svim javnim dionicima, a poglavito političkomu menadžmentu u JLSU-u, u nastavku će biti interpretirani različiti aspekti rezultata koje generira softver *Banxia Frontier Analyst,*

Version 4.1.0 kao podloge za donošenje menadžerskih odluka DO-a u neučinkovitim gradovima uz napomenu da su svi grafički prikazi preuzeti u izvorniku.

Za neučinkovite gradove metoda daje usporedbu relativiziranih empirijskih podataka promatranoga DO-a s gradovima iz referentnoga skupa kao vizualnu podlogu koja prikazuje odnos varijabli. Iako je za potrebe ovoga istraživanja obavljena normalizacija podataka i odnos varijabli je vidljiv iz njihovih empirijskih vrijednosti, ova mogućnost softvera olakšava DO uspoređivanje s benchmarking partnerom na razini vrijednosti odabranih pokazatelja, a ukazuje na opći odnos vrijednosti ističući dobre i loše performanse.

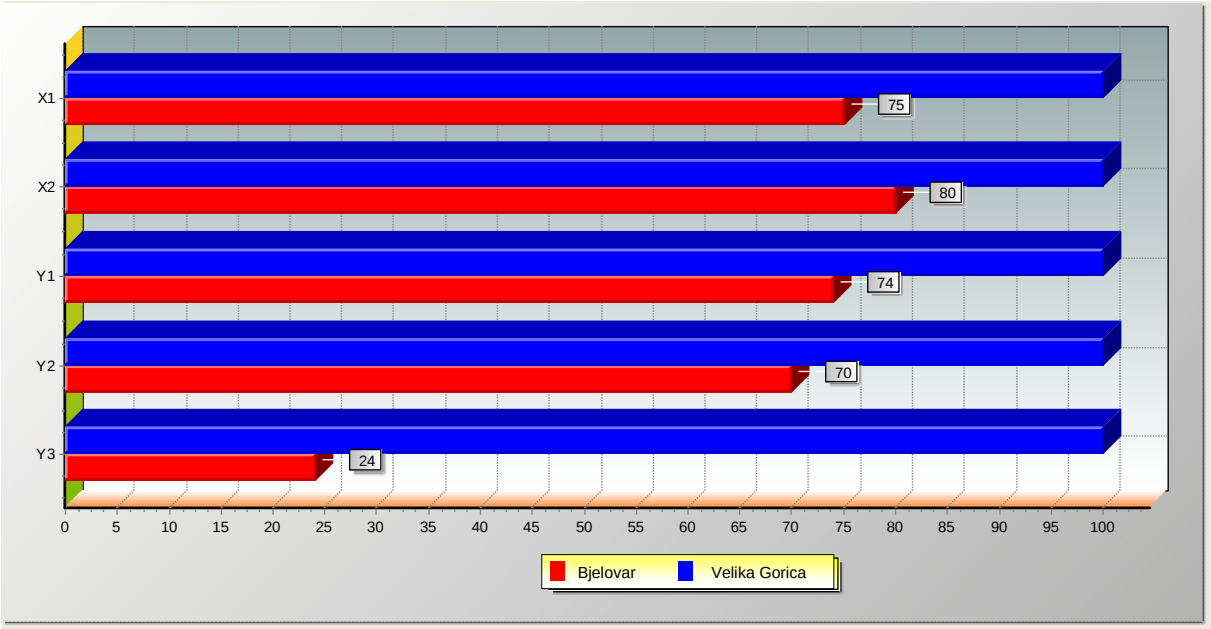
Iako gradovi iz referentnoga skupa s istom ulazno-izlaznom orijentacijom postižu učinkovitost, kao što je već bilo navedeno, za primjer dobre prakse uvijek se odabire grad koji ima najveću vrijednost vektora intenziteta (λ). Stoga su za primjer uzete dvije krajnje benchmarking situacije, iskazane najvećim i najmanjim vektorom intenziteta kako bi se što zornije prikazao postupak odabira referentnoga DO-a za pojedini grad. U slučaju neučinkovita grada Splita model nudi dva referentna grada od kojih grad Vinkovci ima vrijednost λ = 1,08, a Velika Gorica λ = 0,11. Ako se grafički prikaže usporedba relativnih vrijednosti odabranih performansi za grad Split i Vinkovce (*Slika 4-7*) razvidno je da grad Split u gotovo svim performansama ima veće vrijednosti.



Slika 4-7: Referentna usporedba Splita i uzornog grada Vinkovaca

Tako grad Split ima za 162% veće porezne prihode po stanovniku, za 214% veće komunalne prihode po stanovniku, za 146% veće investicije po zaposlenome i za 126% veće plaće od referentnoga grada Vinkovaca.

Za razliku od toga para, najmanju vrijednost vektora intenziteta ima referentni par neučinkovita grada Bjelovara i benchmarking partnera Velike Gorice (*Slika 4-8*).



Slika 4-8: Referentna usporedba Bjelovara i uzornog grada Velike Gorice

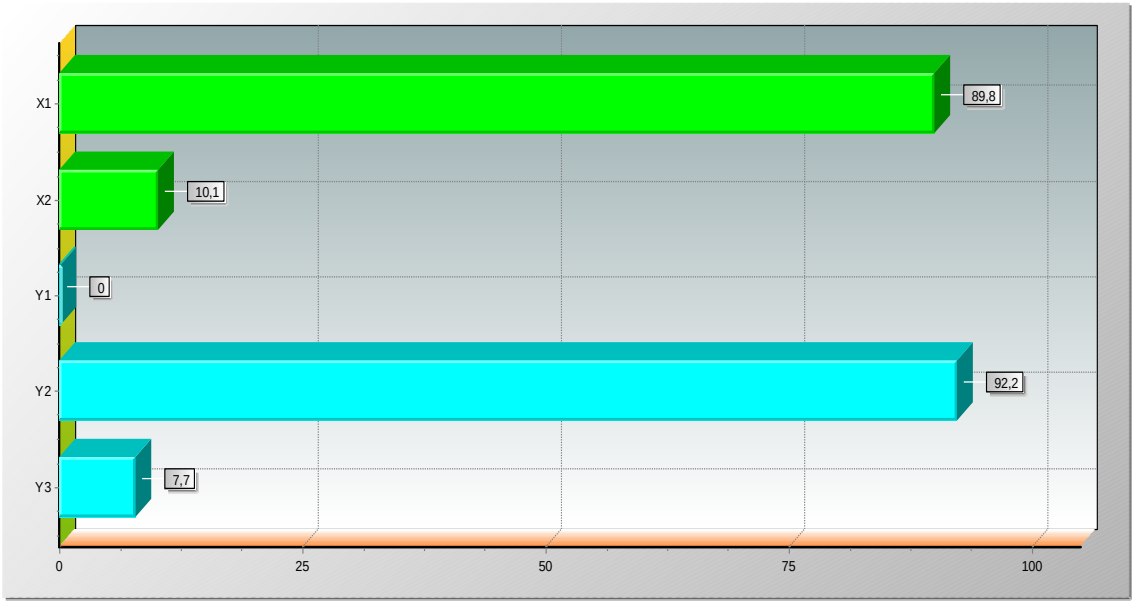
Prema odnosu vrijednosti ključnih normaliziranih empirijskih pokazatelja na *Slici 4-8* između grada Bjelovara i njemu referentnoga grada Velike Gorice, razvidna je obrnuta situacija od prethodne jer neučinkoviti grad Bjelovar u svim empirijskim vrijednostima odabranih performansi „zaostaje“ za referentnim gradom Velikom Goricom. Najveću razliku ima u poreznim prihodima po stanovniku gdje raspolaže samo s 24% resursa u odnosu na Veliku Goricu. U ostalim pokazateljima iskazuje od 70% do 80% vrijednosti u odnosu na referentne pokazatelje Velike Gorice.

Iz prethodnih prikaza može se izvesti zaključak da se iz usporedbe empirijskih podataka odabranih pokazatelja ne može utvrditi razina učinkovitosti i kada bi menadžment na osnovi njih izvodio zaključke i donosio odluke one bi bile nekonzistentne i uglavnom pogrešne. Iako neki autori navode da se na osnovi vrijednosti ulaza i izlaza referentnih jedinica iste veličine mogu definirati ciljevi za povećanje učinkovitosti. Ali u slučaju velikoga broja odabranih performansi i korištenja njihovih apsolutnih vrijednosti, ovaj prikaz može lokalnim vlastima poslužiti kao podloga za jasniju interpretaciju izvora neučinkovitosti i zauzimanje smjernica menadžmenta za planiranje aktivnosti koje će rezultirati pozitivnim promjenama u cilju projekcije identificiranih pokazatelja na granicu učinkovitosti.

Stoga su prema autoru ovoga rada korisniji grafički podatci koji DO interpretiraju težinski odnos ulaza i izlaza i identificiranju izvore neučinkovitosti nudeći njihove postotne promjene koje služe

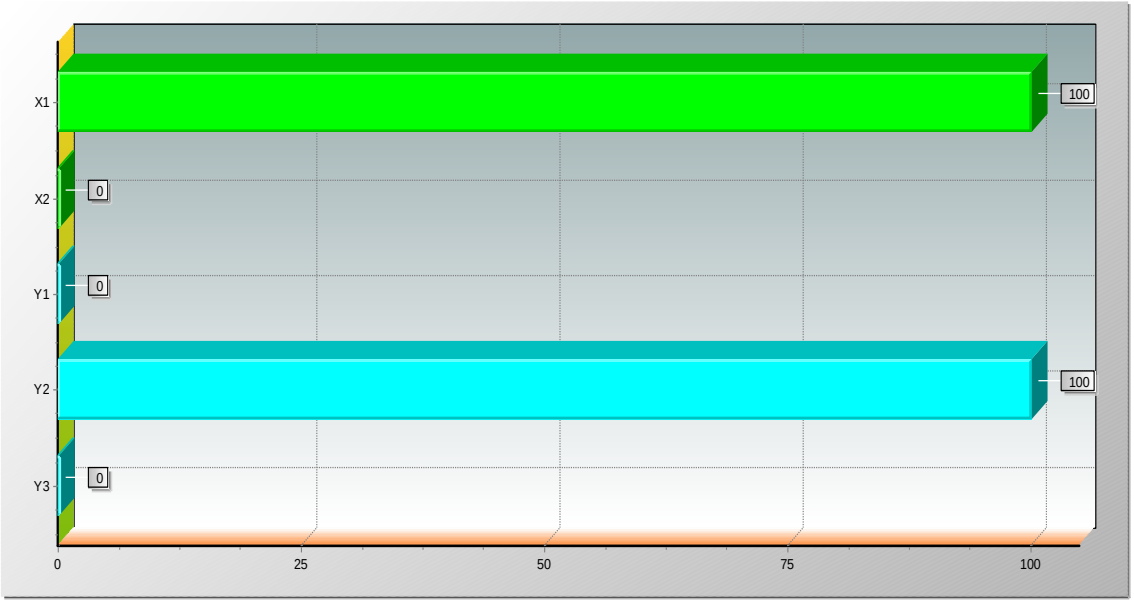
menadžmentu u određivanju smjernica za provedbu promjena u upravljanju u cilju postizanja granice učinkovitosti.

Model analize omeđivanja podataka kreira za svaku jedinicu DO-a virtualnu jedinicu kojoj dodjeljuje optimalne težine ulaza (inputa) i izlaza (outputa) i na taj način maksimalizira rezultate u usporedbi s najboljim jedinicama. Kao što je bilo prije navedeno, gradovi koji definiraju granicu



Slika 4-9: Input – output kontribucija Bjelovar

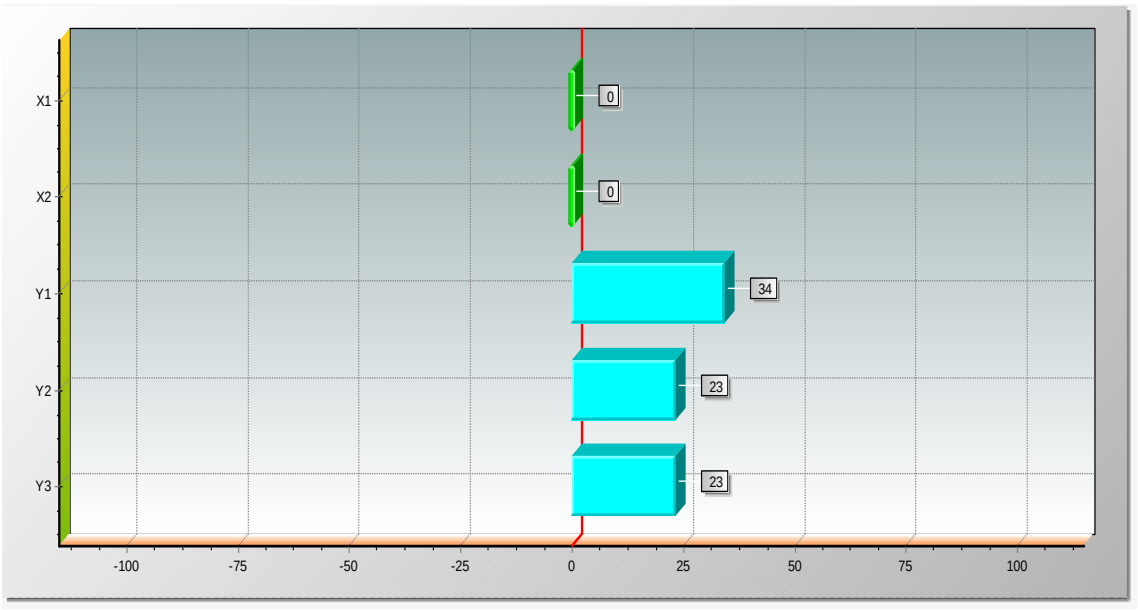
učinkovitosti i čiji rezultati ulaze u skup referentnih (uzornih) jedinica za pojedini neučinkoviti grad, s istim težinama ulaza i izlaza postižu granicu učinkovitosti. Na *Slici 4-9* prikazana je ulazno izlazna orijentacija (kontribucija), odnosno najpovoljniji odnos težina ulaza i izlaza za grad Bjelovar. Dakle svi bi gradovi iz referentne skupine (Slavonski Brod, Velika Gorica i Vinkovci) s takvom ulazno-izlaznom orijentacijom bili efikasni. Kao što je vidljivo dominantan je utjecaj ulaza X_1- *porezni prihodi* (89,9%) i izlaza Y_2 – *prosječna plaća* (92,2%) u odnosu na ostale pokazatelje. Dakle ta slika identificira virtualni grad koji ima optimalan doprinos ulaza i izlaza postignutomu rezultatu. Taj odnos istaknutih ulaza i izlaza posebno je važno analizirati za gradove kod kojih je u projekciji učinkovitosti dominanto sudjelovao samo jedan ili nekoliko pokazatelja dok su drugi zanemareni (*Slika 4-10*). Prema Savić (2012.) takve jedinice treba dodatno analizirati i provjeriti jesu li empirijski podatci za analizu ispravno uneseni i preispitati odabir ključnih pokazatelja. Kao primjer istaknuta je input-output kontribucija u slučaju grada Siska u kojoj su isključena tri pokazatelja iz analize, a u analizu su uključeni samo porezni prihodi, na ulaznoj strani, i prosječna plaća na izlaznoj strani.



Slika 4-10: Input-output kontribucija Sisak

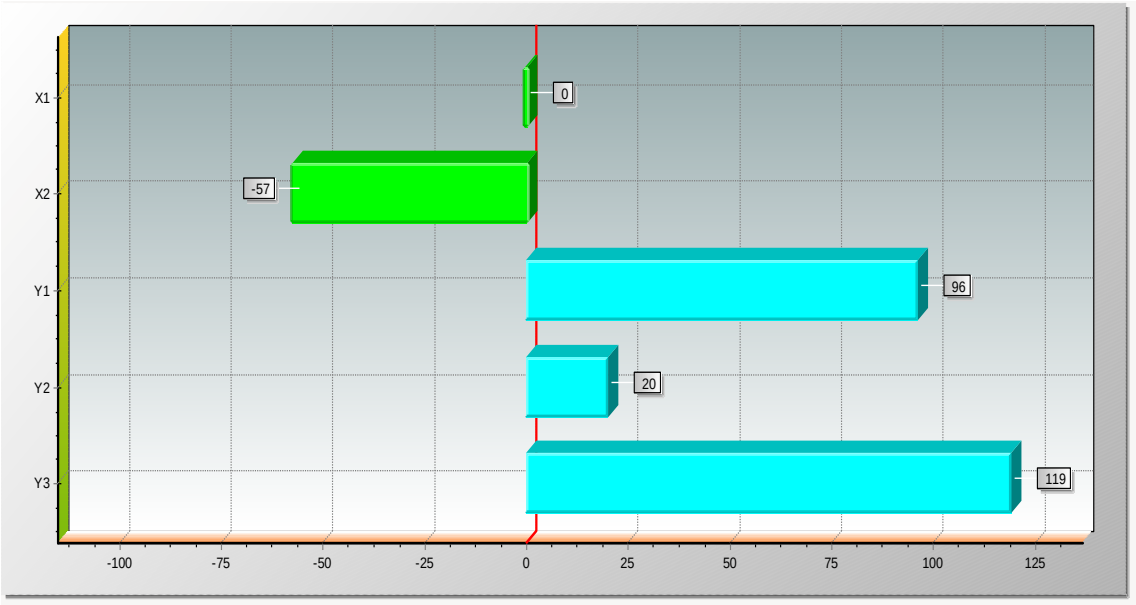
Iako je za ostale pokazatelje istaknuta vrijednost „0“, kao što je ranije bilo izneseno, to ne znači da je njihov udio u ostvarivanju rezultata u potpunosti isključen. Ako istraživač utvrdi da je potrebno korigirati tu situaciju, moguće je uvesti u model ograničavanje vrijednosti težinskih koeficijenata odozgo pri čem se mijenja odnos relativne učinkovitosti, o čijoj se opravdanosti razmimoilaze razmišljanja različitih autora.

Da bi upravljanje gradom Bjelovarom postalo učinkovito, model AOMP-a identificira moguća poboljšanja u sferi ključnih pokazatelja kao što je prikazano na *Slici 4-11*.



Slika 4-11: Korekcija indikatora za projekciju Bjelovara na granicu učinkovitosti

Kao što je vidljivo projekcija grada Bjelovara na granicu učinkovitosti usmjerena je na povećanje izlaza, s nepromijenjenom razinom ulaza, kao posljedica izbora CCR modela koji je izlazno orijentiran. Tako se sugerira DO u gradu Bjelovaru smanjenje stope nezaposlenosti za 34% otvaranjem 1852 radna mjesta, povećanje prosječne plaće za 23% (+795 kn) i investicija po zaposlenome za 23% (+ 3.365 kn). Neki gradovi ne mogu postići granicu učinkovitosti samo povećanjem izlaza, kao što je na primjer grad Sisak (*Slika 4-12*) koji uz povećanje izlaza mora smanjiti trošenje komunalnih prihoda.



Slika 4-12 Korekcija indikatora za projekciju Siska na granicu učinkovitosti

Vlast u gradu Sisku mora, uz smanjenu potrošnju komunalnih prihoda, poduzeti aktivnosti koje će utjecati na smanjenje stope nezaposlenosti za 96%, što u ovome konkretnom slučaju znači otvaranje 1908 novih radnih mjesta, uz istovremene strukturalne promjene koje će utjecati na povećanje prosječne plaće za 20% (+726 kn) i povećanje investicija po zaposlenome za 119%, što nominalno iznosi 13.242 kn. Da bi neučinkovita vlast u Sisku postala učinkovita uzor dobre prakse (eng. *benchmarking*) treba tražiti u Vinkovcima kao referentnomu gradu koji s istom ulazno-izlaznom orijentacijom postiže granicu učinkovitosti.

Dakle taj model identificira izvore neučinkovitosti, daje odgovor na pitanje *što promijeniti* i *u kojoj mjeri* da bi postali učinkoviti, ali ne daje odgovor na pitanje *kako*. Odgovor na ovo posljednje pitanje daje strategija i opredjeljenje političkoga menadžmenta koji upravlja javnim resursima i svojim aktivnostima usmjeruje razvoj gradova.

Ta je činjenica od ključnoga značaja za lokalne vlasti u neučinkovitim gradovima, ali i učinkovitim gradovima koji mogu poboljšati svoje upravljanje kao i svima onima koji na bilo koji način prate njihov rad javne uprave ili su zainteresirani za učinkovito upravljanje javnim resursima.

4.6.3. Analiza prozora (eng. *window*)

Prethodna analiza omeđivanja podataka koncipirana je na usporedbi promatranih jedinica lokalne samouprave s najboljima u skupu, jednokratno za razdoblje na koje se odnose empirijski podaci ključnih performansi. Kao što je bilo navedeno u poglavlju 3.4.1.2., *window* analiza, odnosno analiza prozora uključuje vremensku dimenziju u analizu i na taj način omogućuje određivanje trenda za svaki DO tijekom promatranoga razdoblja. S obzirom na to da će u analizi prozora svaki DO u četverogodišnjem promatranom razdoblju biti tretiran kao zaseban DO i na taj se način povećava broj DO-a na 60, što će generirati realnije rezultate (Savić i Martić, 2009.). U sklopu istraživanja učinkovitosti upravljanja gradovima u Republici Hrvatskoj ta će analiza ukazati na utjecaj (dis)kontinuiteta upravljanja. Dakle za potrebe ovoga istraživanja odabrana su četiri prozora u trajanju od jedne godine, a rezultati takve analize omeđivanja podataka prema izlazno usmjerenom modelu CCR-a su prikazani u *Tablici 4-9*.

Tablica 4-9: Rezultati AOMP analize prozora

JLSU	2005	2006	2007	2008	Prosjek
BJELOVAR	69,47	80,69	66,53	55,77	68,11
DUBROVNIK	62,08	59,16	62,12	64,97	62,08
KARLOVAC	67,52	78,18	58,54	57,81	65,51
OSIJEK	63,27	75,63	56,59	56,62	63,03
PULA	84,28	100,00	87,71	70,14	85,53
RIJEKA	73,48	70,42	53,79	50,90	62,15
SAMOBOR	64,91	75,50	48,63	44,71	58,44
SISAK	77,14	87,13	52,61	57,91	68,70
SLAVONSKI BROD	87,41	100,00	89,08	78,85	88,84
SPLIT	68,23	83,41	54,17	57,93	65,93
ŠIBENIK	97,47	92,65	72,96	66,45	82,38
VARAŽDIN	97,33	100,00	100,00	75,17	93,12
VELIKA GORICA	73,49	100,00	70,89	67,18	77,89
VINKOVCI	88,05	100,00	77,87	78,15	86,02
ZADAR	74,01	98,75	66,84	71,41	77,75
Prosjek	76,54	86,77	67,89	63,60	

Izvor: obrada autora

Za svaki je grad prikazana relativna učinkovitost u određenoj godini u skupu od 60 promatranih DO-a, kao i njihovi prosjeci po redcima i stupcima.

Od svih analiziranih DO-a njih 6 je pokazalo učinkovitost i to pet gradova u 2006. godini i jedan grad u 2007. godini. Svi su gradovi, koji su svrstani u referentni skup učinkovitih DO-a, i u osnovnoj analizi učinkovitosti identificirani kao učinkoviti, dok neučinkoviti gradovi iz osnovne analize nisu pokazali učinkovitost ni u jednoj godini. Ako promatramo trend efikasnosti ni jedan grad nema kontinuirani porast, a može se zaključiti da je njih 87% najbolji rezultat postiglo u drugoj godini mandata, odnosno u 2006. godini. Najveću prosječnu učinkovitost pokazuje grad Varaždin (93%), a najmanju grad Samobor (58%).

Kontinuitet vladanja u gradovima, u vrijeme provedbe ovoga istraživanja može se promatrati dvojako. U pozitivnome smislu on je omogućio stratešku orijentaciju i definiranje dugoročnijih, a samim time i društveno odgovornih politika razvoja. Po mišljenju autora ovoga rada, stabilna izvršna vlast u lokalnim zajednicama znatan je preduvjet za učinkovito upravljanje i pretpostavlja se njegov pozitivan utjecaj na razinu relativne učinkovitosti. Premda se dio nacionalnih resursa raspoređuje na lokalnu razinu po političkome ključu kojemu u znatnoj mjeri pridonose i osobne mreže, odnosno poznanstva i politički utjecaj pojedinaca, neki su gradovi s kontinuiranom vlašću na taj način dovedeni u povlašteni položaj. S druge se strane u javnosti nerijetko ističu negativne strane dugovječnosti vlasti, kao osnovnoga uzroka političkoga klijentelizma u kojem političke elite kroz višegodišnje obnašanje vlasti stvaraju utjecajne mreže koje generiraju devijacije upravljanja javnim resursima po modelu političke sinekure. U kontekstu ovoga istraživanja, utvrđivanje povezanosti kontinuiteta izvršne vlasti u promatranim gradovima i relativne učinkovitosti dodatno će potvrditi utjecaj ljudskih potencijala na učinkovitost upravljanja javnim resursima. U *Tablici 4-10* navedeni su gradonačelnici u promatranim gradovima tijekom jednoga mandata od 2005. do 2008. godine.

Kao što je i vidljivo, prema sjenčanju ćelija u tablici, u pet gradova nije bilo promjene čelnoga čovjeka u izvršnoj vlasti tijekom promatranoga razdoblja već se nastavio kontinuitet iz prethodnoga mandatnog razdoblja. U dvama je gradovima, nakon promjene političke opcije na početku mandata, ostao isti gradonačelnik tijekom cijeloga mandata, a u jednome je došlo do promjene čelnoga čovjeka unutar iste političke stranke. Najdinamičnije je bilo u gradovima Splitu, Karlovcu i Osijeku koji su imali promjenu opcije na početku mandata i smjenu gradonačelnika tijekom mandata.

Tablica 4-10: Podaci o gradonačelnicima u mandatnom razdoblju od 2005. do 2008. godine

JLSU	2005.	2006.	2007.	2008.
Bjelovar	Đurđa Adlešić	Đurđa Adlešić	Đurđa Adlešić	Antun Korošec
Dubrovnik	Dubravka Šuica	Dubravka Šuica	Dubravka Šuica	Dubravka Šuica
Karlovac	Božo Joha/ Miro Škrgatić	Miro Škrgatić	Damir Jelić	Damir Jelić
Osijek	Zlatko Kramarić/ Anto Đapić	Anto Đapić	Anto Đapić	Goran Matković
Pula	Luciano Delbianco/ Valter Drandić	Valter Drandić	Boris Miletić	Boris Miletić
Rijeka	Vojko Obersnel	Vojko Obersnel	Vojko Obersnel	Vojko Obersnel
Samobor	Žarko Adamek/ Filipec A. Dubravko	Filipec Antun Dubravko	Filipec Antun Dubravko	Filipec Antun Dubravko
Sisak	Dinko Pintarić/ Davorko Vidović	Dinko Pintarić	Dinko Pintarić	Dinko Pintarić
Slavonski Brod	Jozo Meter/ Mirko Duspara	Mirko Duspara	Mirko Duspara	Mirko Duspara
Split	Miroslav Buličić/ Zvonimir Puljić	Zvonimir Puljić	Zvonimir Puljić/ Ivan Kuret	Ivan Kuret
Šibenik	Nedjeljka Klarić	Nedjeljka Klarić	Nedjeljka Klarić	Nedjeljka Klarić
Varaždin	Ivan Čehok	Ivan Čehok	Ivan Čehok	Ivan Čehok
Velika Gorica	Ivan Šuker/ Tonino Picula	Tonino Picula	Tonino Picula	Tonino Picula
Vinkovci	Mladen Karlić	Mladen Karlić	Mladen Karlić	Mladen Karlić
Zadar	Ana Lovrin/ Živko Kolega	Živko Kolega	Živko Kolega	Živko Kolega
Tumač boja	Promjena političke opcije	Promjena unutar iste političke opcije	Nastavak mandata unutar iste opcije	Kontinuitet vlasti

Izvor: obrada autora

Ako usporedimo relativnu učinkovitost gradova i prosječnu učinkovitost dobivenu analizom prozora s kontinuitetom upravljanja izraženu postojanošću čelnoga čovjeka u promatranome mandatu, možemo zaključiti sljedeće:

- U Dubrovniku, Rijeci, Šibeniku, Varaždinu i Vinkovcima se nastavio kontinuitet vlasti iz prethodnoga mandata i ostao je tijekom cijeloga mandata. Od tih pet gradova, tri su učinkovita i definiraju granicu učinkovitosti prema CCR modelu AOMP-a (Dubrovnik, Varaždin i Vinkovci),
- U Velikoj Gorici, Slavonskom Brodu, Samoboru i Zadru je nakon promjene političke opcije na početku mandata gradonačelnik obnašao dužnost tijekom cijeloga mandata, a u toj skupini dva grada pokazuju učinkovitost, a dva su neučinkovita;

- U detaljnoj analizi utjecaja smjene vlasti na učinkovitost, promatranjem ostvarene razine učinkovitosti prije i u godini smjene čelnoga čovjeka može se zaključiti da je u tri grada došlo do smanjenja, a u dva do povećanja učinkovitosti dok se u jednome gradu nije promijenila relativna učinkovitost;
- Ako se izračuna koeficijent korelacije između prosječnih učinkovitosti gradova dobivena analizom prozora i koeficijenta postojanosti vlasti[55] dobije se pozitivna korelacija 0,33 (*P=0,2292*) što ukazuje na laku povezanost koja nije statistički značajna.

Zbog kratka perioda promatranja i nepoznavanja okolnosti smjenâ gradonačelnika ne može se sa sigurnošću utvrditi utjecaj kontinuiteta vlasti na učinkovitost upravljanja, ali se može zaključiti da se najveća učinkovitost postiže u godini nakon izbora, a prema slijedećim izborima opada. Pretpostavka je politički pragmatizam koji podređuje ostvarivanje dugoročnih razvojnih politika kratkoročnim ciljevima koji će omogućiti kontinuitet vladanja.

4.7. Analiza učinkovitosti s nediskrecijskim ulazima

Za potvrđivanje pretpostavki izraženih četvrtom hipotezom u ovom će se poglavlju izračunati relativna učinkovitost upravljanja gradovima u kojem će se uzeti ulazi na koje DO nemaju utjecaj tzv. nediskrecijski, dok će izlazi ostati isti. Svrha je te analize utvrditi u kojoj se mjeri može usmjeriti analiza omeđivanja podataka na ljudske potencijale izborom karakterističnih performansi koje (ni)su u domeni utjecaja određenoga DO-a. Za potrebe analize učinkovitosti upravljanja velikim gradovima u Republici Hrvatskoj identificirana su dva nediskrecijska ulaza:

- $\boldsymbol{X_3}$ - Prosječan broj RAS,
- $\boldsymbol{X_4}$ - Dohodak po stanovniku (omjer ukupnoga iznosa dohotka koji su tijekom jednoga poreznog razdoblja/kalendarske godine ostvarili porezni obveznici, fizičke osobe s prebivalištem ili boravištem na području grada i broja stanovnika koji žive na području grada).

Podaci za ulaze x_3 i x_4 su izraženi kao četverogodišnji prosjek razdoblja od 2004. do 2008. godine, a s obzirom na to da se izražavaju različitim jedinicama, isti su normalizirani (*Tablica 4 – 2)*. Rezultati relativne učinkovitosti upravljanja gradovima prema CCR modelu usmjerenom na izlaze prema nediskrecijskim i diskrecijskim ulazima, prikazani su u Tablici 4–11 .

[55] Koeficijent postojanosti vlasti iskazan je na slijedeći način: 1-kontinuitet vlasti, 0,9-smjena vlasti iste političke opcije, 0,85 – smjena političke opcije nakon izbora, 0,75-smjena političke opcije na izborima i unutar političke opcije tijekom mandata, 0,7-smjena političke opcije tijekom mandata

Tablica 4-11: Usporedba relativne učinkovitosti diskrecijskih i nediskrecijskih ulaza

DO	Relativna CCR učinkovitost *nediskrecijski inputi*	Relativna CCR učinkovitost *diskrecijski inputi*
Bjelovar	82,88%	80,97%
Dubrovnik	100,00%	100,00%
Karlovac	82,50%	82,42%
Osijek	79,65%	74,35%
Pula	100,00%	100,00%
Rijeka	82,20%	73,61%
Samobor	85,62%	66,79%
Sisak	75,87%	83,22%
Slavonski Brod	99,31%	100,00%
Split	81,33%	79,67%
Šibenik	82,15%	92,91%
Varaždin	100,00%	100,00%
Velika Gorica	100,00%	100,00%
Vinkovci	88,89%	100,00%
Zadar	95,11%	96,25%

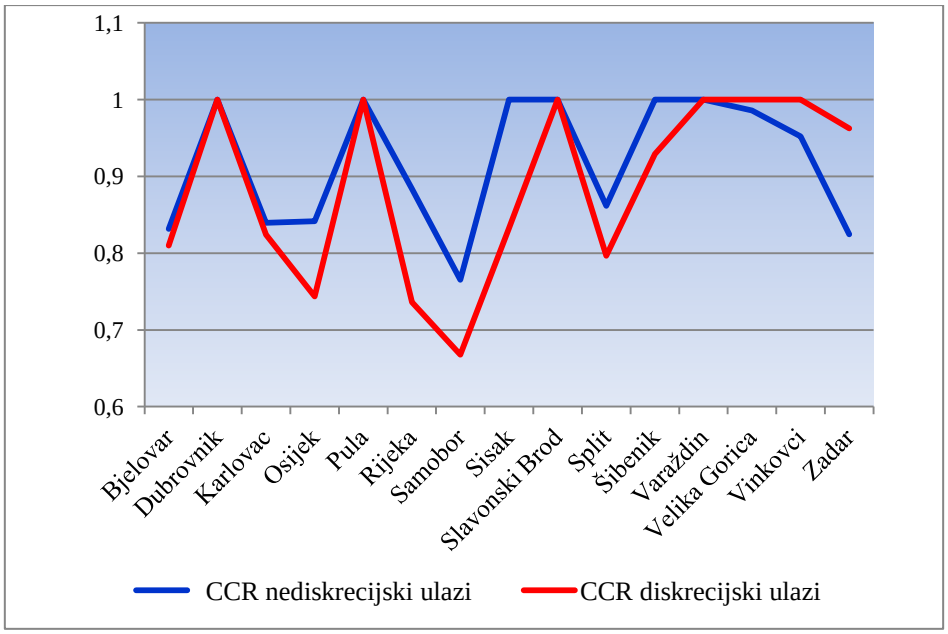
Izvor: obrada autora

Usporedba rezultata relativne učinkovitosti CCR modela s diskrecijskim i nediskrecijskim ulazima pokazuje razlike u učinkovitosti nekih gradova pri čem najznačajniju razliku pokazuje učinkovitost Samobora (18,8 postotnih poena), Vinkovaca (11 postotnih poena) i Šibenika (10,7 postotnih poena).

Na grafičkome prikazu (*Slika 4-13*) zorno je prikazano da granicu učinkovitosti u oba modela definiraju svi učinkoviti gradovi iz osnovnoga istraživanja prema diskrecijskim ulazima osim grada Vinkovaca. Unatoč navedenim razlikama, utvrđena relativna učinkovitost prema ulazima s različitim stupnjem utjecaja lokalnih vlasti prema koeficijentu korelacije 0,75**[56] pokazuje visok stupanj povezanosti.

Iz navedenoga se može zaključiti da promjena karakterističnih pokazatelja izvan izravne ovlasti DO-a utječe na promjene relativne učinkovitosti i DO-a koji definiraju frontu učinkovitosti, ali ukupni rezultati pokazuju visok stupanj korelacije.

[56] Statistički značajna (signifikantna) korelacija P<0,05,



Slika 4-13: Prikaz relativne učinkovitost prema diskrecijskim i nediskrecijskim ulazima

Ta analiza nije imala svrhu testiranja relativne učinkovitosti već će poslužiti za usporedbu učinkovitosti s pokazateljima ekonomskoga razvoja gradova kao materijalne osnove za razvoj u odnosu na kompetentnost lokalnoga političkog menadžmenta, odnosno ljudskih potencijala lokalnih vlasti, što će biti obrađeno u sljedećim poglavljima.

4.8. Odnos učinkovitosti upravljanja i ekonomske razvijenosti gradova

S obzirom na to da su se u analizi omeđivanja podataka kao rezultati učinkovitoga upravljanja gradovima koristili ekonomski pokazatelji čija veličina izravno ovisi o snazi gospodarstva određenoga grada (stopa nezaposlenosti, prosječne plaće i investicije po zaposlenome) kao i o stupnju ekonomske razvijenosti, u ovom će se poglavlju utvrditi povezanost dobivenih rezultata s pokazateljima gospodarskoga potencijala gradova koji će biti izražen indeksom razvijenosti i indeksom ekonomske efikasnosti.

4.8.1. Odnos učinkovitosti upravljanja i indeksa razvijenosti

Kao što je bilo navedeno u poglavlju 4.3. *Indeks razvijenosti* definiran je na osnovi Zakona o regionalnom razvoju Republike Hrvatske (Narodne novine 153/2009), a utvrđen je *Odlukom o razvrstavanju jedinica lokalne i područne (regionalne) samouprave prema stupnju razvijenos*ti (Narodne novine broj 89/2010 i 158/2013). Na osnovi indeksa razvijenosti sve jedinice lokalne samouprave svrstane su u pet skupina koje su određene stupnjem razvoja u odnosu na nacionalni prosjek. Uredbom o Indeksu razvijenosti (Narodne novine broj 63/2010) propisan je postupak izračuna prema kojemu se Indeks razvijenosti izračunava na osnovi sljedećih pokazatelja:

a. stope nezaposlenosti,
b. dohotka po stanovniku,
c. proračunskih prihoda JLSU-a po stanovniku,
d. općeg kretanja stanovništva,
e. stope obrazovanosti.

- Stopa nezaposlenosti se izračunava kao omjer broja nezaposlenih i broja radno aktivnoga stanovništva na području pojedine jedinice lokalne, odnosno područne (regionalne) samouprave;
- Dohodak po stanovniku izračunava se kao omjer ukupnoga iznosa dohotka koji su tijekom jednoga poreznog razdoblja (kalendarske godine) ostvarili porezni obveznici, fizičke osobe s prebivalištem na području JLSU-a i broja stanovnika koji žive na području te jedinice;
- Dohodak je utvrđen prema Zakonu o porezu na dohodak, a uključuje ukupni iznos ostvarenoga dohotka prema svim izvorima oporezivoga dohotka, uključujući i dobit koju su ostvarile fizičke osobe od obavljanja samostalne djelatnosti;
- Proračunski prihodi JLSU-a po stanovniku iskazuju omjer ostvarenih prihoda umanjenih za određene skupine prihoda i broja stanovnika;
- Opće kretanje stanovništva predstavlja omjer usporedivoga broja stanovnika JLSU-a u dvama posljednjim popisima stanovništva Republike Hrvatske;
- Stopa obrazovanosti predstavlja udjel stanovništva sa završenom srednjom školom i višom razinom obrazovanosti u ukupnome stanovništvu, u dobi između 16 i 65 godina, na području JLSU-a.

Uz pretpostavku da ekonomski procesi ne proizvode jednake učinke u svim jedinicama lokalne samouprave, a da stupanj ekonomskoga razvoja gradova izravno utječe na alokaciju proizvodnih potencijala i njihovu efikasnost, važno je za ovo istraživanje utvrditi stupanj korelacije učinkovitosti upravljanja javnim resursima i indeksa razvijenosti.

U *Tablici 4-12* prikazan je odnos Indeksa razvijenosti i relativne učinkovitosti gradova prema CCR modelu za diskrecijske i nediskrecijske ulaze.

Vrijednosti koeficijenta korelacije između izračunate relativne učinkovitosti na osnovi diskrecijskih ulaza i indeksa razvijenosti gradova iznosi – 0,08 (*P=0,7838*). S obzirom na negativan predznak on označava negativnu korelaciju dviju varijabli odnos u kojem porast vrijednosti jedne varijable implicira pad vrijednosti druge varijable. Vrijednost koeficijenta ukazuje na nikakvu ili neznatnu povezanost, a sam koeficijent nije statistički značajan. Iz

navedenoga može se zaključiti da relativna učinkovitost upravljanja gradovima u Republici Hrvatskoj i indeks razvijenosti nisu povezani pokazatelji.

Tablica 4-12: Odnos indeksa razvijenosti hrvatskih gradova i učinkovitosti upravljanja

JLSU	Relativna CCR učinkovitost */diskrecijski /*	Relativna CCR učinkovitost */nediskrecijski /*	Indeks razvijenosti
	I	*II*	*III*
Bjelovar	80,97%	82,88%	92,55%
Dubrovnik	100,00%	100,00%	121,11%
Karlovac	82,42%	82,50%	96,14%
Osijek	74,35%	79,65%	102,65%
Pula	100,00%	100,00%	120,33%
Rijeka	73,61%	82,20%	119,20%
Samobor	66,79%	85,62%	119,79%
Sisak	83,22%	75,87%	104,38%
Slavonski Brod	100,00%	99,31%	87,45%
Split	79,67%	81,33%	108,18%
Šibenik	92,91%	82,15%	100,52%
Varaždin	100,00%	100,00%	122,62%
Velika Gorica	100,00%	100,00%	110,18%
Vinkovci	100,00%	88,89%	89,86%
Zadar	96,25%	95,11%	104,82%
Koeficijent korelacije	I/III -0,08	II/III 0,29	

Izvor: obrada autora

Za razliku od prethodne, relativne učinkovitosti prema CCR modelu izračunata na osnovi nediskrecijskih ulaza pokazuje pozitivan smjer i malu povezanost s indeksom korelacije 0,29 (P=0,2907).

Iz navedenoga se može zaključiti da stupanj razvijenosti promatranih jedinica pokazuje veću povezanost s učinkovitošću upravljanja kada se ona računa na osnovi pokazatelja koji nisu u izravnoj nadležnosti DO-a.

4.8.2. Odnos učinkovitosti upravljanja i indeksa ekonomske efikasnosti

Indeks ekonomske efikasnosti gradova u Republici Hrvatskoj mjera je efikasnosti gospodarskih subjekata, odnosno tvrtki, koje u njima posluju. Istraživanje je proveo Razvojni forum Zagreb u razdoblju od 2004. do 2009. godine na osnovi analize sljedećih pokazatelja:

- usporediva efikasnost poslovnih sredstava, kao omjer dohotka i poslovnih sredstava,

- izvozna usmjerenost, izražena udjelom izvoza u ukupnim prihodima,
- profitabilnost, kao omjer ostvarenoga profita i kapitala,
- proizvodnost rada, kao omjer dohotka i broja zaposlenih,
- investicije u dugotrajnu imovinu, iskazanu udjelom na početku razdoblja.

Taj pokazatelj odražava stupanj efikasnosti gospodarstva pojedinoga grada u odnosu na druge gradove. Odnos relativne CCR učinkovitosti velikih gradova u Republici Hrvatskoj i indeksa ekonomske efikasnosti njihova gospodarstva prikazan je u *Tablici 4-13*. Koeficijenti korelacije pokazuju sličan odnos učinkovitosti upravljanja velikim gradovima prema CCR modelu s razinom ekonomske efikasnosti gospodarstva kao i s indeksom razvijenosti gradova.

Tablica 4-13: Odnos indeksa ekonomske efikasnosti i učinkovitosti upravljanja

JLSU	Relativna CCR učinkovitost */diskrecijski /*	Relativna CCR učinkovitost */nediskrecijski /*	Indeks ekonomske efikasnosti
	I	*II*	*III*
Bjelovar	80,97%	82,88%	95,88
Dubrovnik	100,00%	100,00%	117,28
Karlovac	82,42%	82,50%	105,38
Osijek	74,35%	79,65%	98,33
Pula	100,00%	100,00%	97,83
Rijeka	73,61%	82,20%	119,5
Samobor	66,79%	85,62%	105,45
Sisak	83,22%	75,87%	72,43
Slavonski Brod	100,00%	99,31%	97,95
Split	79,67%	81,33%	92,65
Šibenik	92,91%	82,15%	97,13
Varaždin	100,00%	100,00%	102,53
Velika Gorica	100,00%	100,00%	99,00
Vinkovci	100,00%	88,89%	91,83
Zadar	96,25%	95,11%	112,45
Koeficijent korelacije	I/III -0,01	II/III 0,37	

Izvor: obrada autora

Povezanost varijabli relativne učinkovitosti upravljanja izračunate iz diskrecijskih ulaza po CCR metodi izlazne orijentacije i indeksa ekonomske efikasnosti gotovo ne postoji. Koeficijent korelacije negativnim predznakom označava suprotan odnos varijabli, a veličina r= – 0,01 (P=0,9707) označava da nema povezanosti između tih dviju varijabli.

S druge strane odnos relativne učinkovitosti gradova izračunat iz nediskrecijskih ulaza po istome modelu i indeksa ekonomske efikasnosti pokazuje malu pozitivnu povezanost varijabli koja se bilježi koeficijentom korelacije r=0,37 koji nije statistički signifikantan (P=0,1734).

Iako je to na prvi pogled bilo i očekivano, usporedbom relativne učinkovitosti upravljanja u dvije varijante izračuna s pokazateljima ekonomskoga razvoja određenoga grada, iskazanoga stupnjem razvoja i gospodarskim potencijalom, potvrđene su pretpostavke da učinkovitost upravljanja ovisi primarno o kompetencijama političkoga menadžmenta u odnosu na izdašnost resursa kojima oni raspolažu.

4.9. Interpretacija rezultata istraživanja

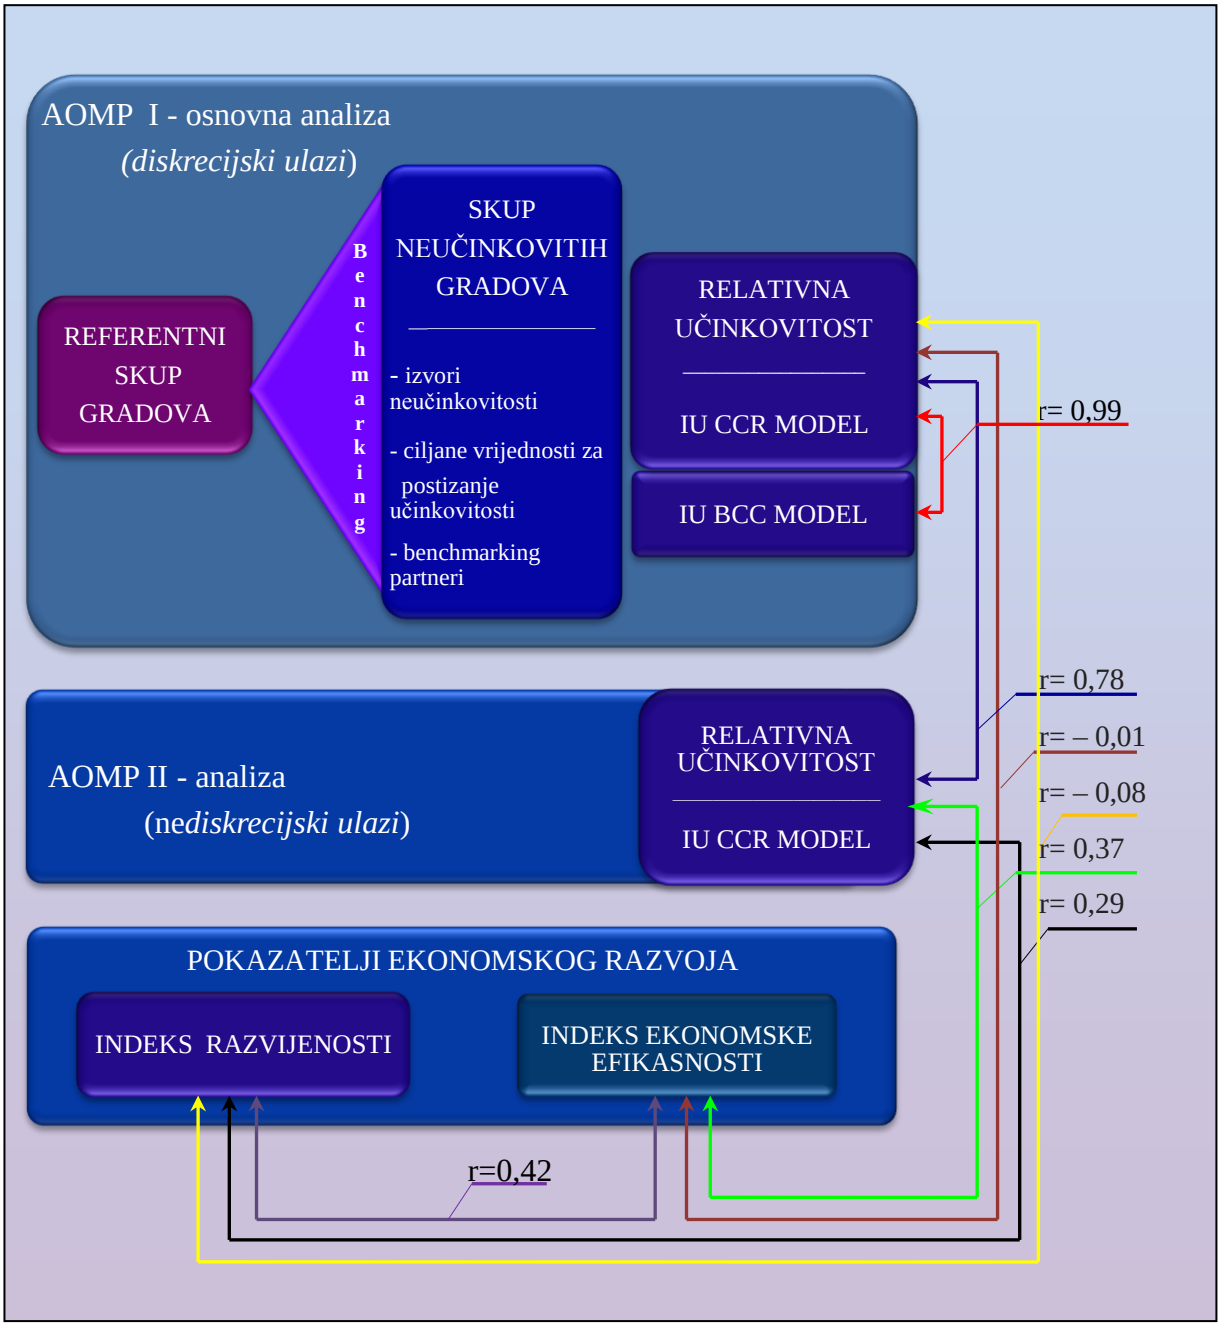
S obzirom na to da je istraživanje provedeno u nekoliko faza, a rezultati su izneseni u zasebnim poglavljima, za potpuno razumijevanje i izvođenje zaključaka potrebno ih je sažeti i interpretirati u kontekstu ovoga rada i usporediti ih sa zadanim ciljevima istraživanja i definiranim hipotezama. Struktura istraživanja prikazana na *Slici 4-14* prikazuje međusobnu povezanost osnovnoga istraživanja relativne učinkovitosti gradova i izvedenih istraživanja. Kao mjera povezanosti varijabli odabranih pokazatelja koji su uključeni u analizu istaknuti su koeficijenti korelacije na osnovi kojih će biti interpretirani postignuti rezultati.

Osnovna analiza učinkovitosti velikih gradova u Republici Hrvatskoj imala je zadatak identificirati učinkovite gradove koji su svrstani u skup referentnih DO-a koji definiraju granicu učinkovitosti i predstavljaju benchmarking partnere neučinkovitim gradovima. U analizu je uključeno pet pokazatelja, a ulazi (resursi) su odabrani iz diskrecijske domene lokalnih vlasti.

Za neučinkovite gradove identificirani su izvori neučinkovitosti i predložena poboljšanja u racionalnome korištenju resursa i ostvarivanju boljih rezultata, kao osnova za postavljanje ciljeva DO-a za projekciju na granicu učinkovitosti. Analiza je obavljena prema izlazno usmjerenim modelima koji pretpostavljaju konstantne prinose (CCR) i varijabilne pronose (BCC), a rezultati pokazuju da te dvije varijable pokazuju izvrsnu povezanost (r=0,99**). Iako je već prije konstatirano da nema razlike u učinkovitosti s obzirom na opseg poslovanja, visoka povezanost rezultata učinkovitosti prema dvama korištenim modelima dodatno potvrđuje tu pretpostavku i opravdava korištenje samo IU CCR modela u nastavku istraživanja.

Učinkovitost gradova dobivena izračunom IU CCR modela analize omeđivanja podataka s uključenim nediskrecijskim ulazima (AOMP II) pokazuje visoku povezanost s relativnom

učinkovitošću dobivenom u osnovnoj analizi s diskrecijskim ulazima (r=0,78**). Taj rezultat ukazuje na objektivan odabir ključnih resursa koji su uključeni u model, ali i konzistentnost rezultata relativne učinkovitosti koja se nije znatno promijenila supstitucijom oba ulaza (inputa).



Slika 4-14: Pregled odnosa varijabli uključenih u istraživanje

Odabrani pokazatelji ekonomskoga razvoja velikih gradova identificiraju potencijale određenih gradova koji se odnose na ekonomsku snagu gospodarstva izraženu Indeksom ekonomske efikasnosti i razinu ekonomske razvijenosti u usporedbi s nacionalnom razinom izraženu Indeksom razvijenosti. Stavljajući te dvije varijable u međusobni odnos izračunom koeficijenta

korelacije, utvrđena je umjerena pozitivna povezanost (r=0,42) koja nije statistički signifikantna (P=0,1189), što je u skladu s očekivanjima.

Rezultati korelacijske analize između relativne učinkovitosti prema IU CCR modelu s diskrecijskim ulazima i oba pokazatelja ekonomske razvijenosti ne pokazuju nikakvu povezanost varijabli uz negativan predznak (r= –0,01; r= –0,08). Iz čega se može zaključiti da ekonomska razvijenost gradova i odabrani indikatori relativne učinkovitosti nisu povezane varijable te da razina ekonomske razvijenosti ne utječe na učinkovitost upravljanja javnim resursima, što je bio jedan od glavnih ciljeva ovoga istraživanja.

S druge strane uzme li se u korelacijsku analizu relativna učinkovitost prema IU CCR modelu s nediskrecijskim ulazima, koeficijenti korelacije s istim pokazateljima ekonomske razvijenosti pokazuju pozitivnu malu povezanost (r= 0,29; r= 0,37). Ti rezultati upućuju na zaključak da stupanj ekonomske razvijenosti gradova u znatnijoj mjeri utječe na rezultate analize relativne učinkovitosti upravljanja javnim resursima u slučaju odabira ključnih pokazatelja izvan diskrecijske domene DO-a.

Navedeni rezultati potvrđuju postavljene hipoteze u ovoj disertaciji i pridonose ostvarivanju ciljeva istraživanja, što će biti detaljnije obrazloženo u zaključnom poglavlju.

4.10. Mogućnosti implementacije AOMP-a u informacijskim sustavima

Kao što je bilo istaknuto u prethodnim poglavljima, konkurentske prednosti lokalne samouprave ne zasnivaju se isključivo na fizičkim resursima već na kompetentnome menadžmentu i nematerijalnim resursima. To su tzv. *soft* resursi kojima je u osnovi znanje i na njem zasnovano donošenje odluka u procesu upravljanja. Prema statističkim podatcima organizacije koriste ograničene spoznaje u donošenju odluka koje se zasnivaju na cca 10% dostupnih informacija ili ih u većini slučajeva menadžment donosi intuitivno (Panian, 2003). Samosvijest lokalnih vlasti i nastojanje da se ponovno dobije povjerenje birača na lokalnim izborima, utječu na traženje novih tehnoloških rješenja i kontinuiranu modernizaciju procesa upravljanja koji se neizostavno oslanjaju na informacijsku tehnologiju. U nedostatku kvalitetnih informatičkih alata i sustava za javnu upravu, lokalna samouprava preuzima od profitnoga sektora norme i sustave koje taj sektor brže razvija i prihvaća. Tomu u znatnoj mjeri pridonosi politički angažman poduzetnika koji sa sobom u javnu upravu donose alate i metode koje su koristili u profitnome sektoru. Iako je suvremena paradigma poslovanja u učinkovitoj javnoj upravi nezamisliva bez informatizacije i primjene suvremenih informacijskih sustava koji omogućuju implementaciju specifičnih znanja u procese upravljanja, primjena je najčešće ograničena na jednostavnija rješenja. Kao što je

vidljivo, rezultati provedenoga istraživanja na osnovi metode analize omeđivanja podataka daju obilje informacija koje DO moraju sistematizirati, obraditi i iskoristiti one koje im mogu pomoći u donošenju pravih poslovnih odluka i poteza.

Ako „učinkovitost upravljanja“ promijenimo u „upravljanje učinkom“ dobijemo procesnu implikaciju koja podrazumijeva pozorno planiranje svih dijelova poslovanja i kreiranje ključnih pokazatelja radi dobivanja jasne slike kako određena javna uprava zaista posluje u svojem poslovnom okruženju, identifikacije izvora i razloga neučinkovitosti i mogućnosti dostizanja razine učinkovitosti svojih referentnih jedinica.

Budući da na rezultate učinkovitosti upravljanja utječe velik broj vanjskih čimbenika, na koje lokalne vlasti nemaju izravan utjecaj (tzv. *nediskrecijski*), DO se u pravilu suočavaju s činjenicom da je potrebno identificirati odstupanja i obrazložiti zašto su se dogodila i raspolagati kvalitetnim informacijama „na dnevnoj razini“ kako bi mogli kreirati događaje, a ne reagirati na njih nakon obračunskoga razdoblja. Praćenje učinaka pomoću ključnih pokazatelja koje analiziramo AOMP metodom, unatoč dinamičkoj dimenziji koju nudi analiza prozora (*window analiza*) ograničeno je na razdoblje prikupljanja i obrade podataka koji se najčešće odnose na godišnje razdoblje. Dakle lokalne se vlasti ne mogu koristiti samo AOMP-om ako žele u realnome vremenu analizirati postignute učinke u usporedbi sa zadanim ciljevima i pozicionirati se u skupu usporedivih jedinica.
Upravo se u tome dijelu javlja potreba za korištenjem sustava koji od skupa podataka koji se generiraju u procesima javnoga upravljanja može producirati kvalitetne informacije i pomoću analitičkih alata omogućiti njihovu primjenu prema zahtjevu menadžmenta i ostalih dionika koji prate proces javnoga upravljanja.

Upravo takve mogućnosti nudi sustav poslovne inteligencije (PI) koji je u primarnome obliku kreiran za poslovnu špijunažu, u cilju prikupljanja informacija koje će povećati uspješnost tvrtke u odnosu na konkurenciju (tzv. “James Bond BI”). Danas poslovna inteligencija predstavlja skupinu novih softverskih aplikacija oblikovanih tako da mogu organizirati i strukturirati podatke o poslovnim transakcijama na način koji omogućuje analizu korisnu u potpori odlučivanju i operativnim aktivnostima organizacije. S obzirom na to da sustav PI pridonosi generiranju kvalitetnih informacija u realnome vremenu na osnovi kojih menadžment donosi operativne odluke, autor ovoga rada smatra opravdanim analizu mogućnosti povezivanja metode analize omeđivanja podataka i sustava poslovne inteligencije u cilju unaprjeđenja same metode i stvaranja cjelovita koncepta upravljanja učinkovitošću u lokalnoj samoupravi.

4.10.1. Analiza omeđivanja podataka kao dio sustava poslovne inteligencije

U javnoj upravi, kao složenu sustavu koji obiluje podatcima, postoji izražena potreba obrade podataka u informacije koje se korištenjem u procesu upravljanja i odlučivanja mogu pretvoriti u znanja. Kao što je u prethodnim poglavljima bilo istaknuto, brojni podaci koji se statistički prikupljaju o poslovanju lokalne samouprave i ekonomskim potencijalima lokalnih zajednica bez sustava obrade i alata koji omogućuje njihovu analizu nisu od velike koristi menadžmentu ni javnim dionicima. Brojna statistička izvješća i pohranjivanje raznih podataka u baze podataka oslikavaju trenutačno stanje u jedinci na koju se odnose, ali zbog statičnosti i ograničene upotrebe na njih se ne gleda kao na izvor znanja. Ne postoje informacije u izvornome obliku (neobrađene) koje mogu poslužiti kao inputi za odlučivanje, što su i pokazali rezultati provedenoga istraživanja AOMP-om.

Transformaciju podataka u korisno znanje nudi sustav poslovne inteligencije (eng. *Business intelligence*, BI) koji objedinjuje aplikacije i tehnologije za prikupljanje, skladištenje i analiziranje podataka bitnih za donošenje odluka (Pavlović, 2012.). Poslovna inteligencija najčešći je oblik prijevoda engleskoga izraza koji se u hrvatskome jeziku prevodi još kao upravljanje poslovnim informacijama, poslovno obavješćivanje, poslovno istraživanje, poslovno izvješćivanje, poslovne izvjesnice, poslovno-obavještajna aktivnost i sl. U daljnjem će se tekstu koristiti izraz poslovna inteligencija (PI), a podrazumijevat će sustav podrške odlučivanju u lokalnoj samoupravi koji je zasnovan na dostupnim i kvalitetnim informacijama. Povijest razvoja sustava poslovne inteligencije vezan je uz razvoj automatiziranosti poslovnih procesa u profitnome sektoru, odnosno implementacije različitih transakcijskih sustava koji su se vrlo brzo pokazali kao generatori velikih količina podataka. Razvoj informacijske komunikacijske tehnologije omogućio je analizu tih informacija u cilju prilagodbe procesima odlučivanja. Iako postoje brojne definicije sustava poslovne inteligencije, sve se mogu sažeti u predstavljanje poslovne inteligencije kao skup alata i metodologija koji se koriste u cikličkome procesu transformacije podataka u informacije, odnosno njihovu pretvaranju u znanje koje se koristi u procesu donošenja odluka. S gledišta informacijskih tehnologija, poslovna inteligencija objedinjuje metodologije, tehnologije i platforme za skladištenje podataka, procesiranje podataka i rudarenje podataka, koje korisnicima omogućuju kreiranje korisnih upravljačkih informacija iz podataka o poslovanju što se nalaze disperzirani na različitim transakcijskim sustavima, te dolaze iz različitih internih i eksternih sustava (Luetić, 2009.). Prema Javoroviću (2007.) poslovna inteligencija ima sljedeće odrednice:

- PI je proces prikupljanja podataka i informacija koji nakon odgovarajuće obrade postaju „znanje“,
- aktivnosti su usmjerene na informacije na osnovi kojih se mogu anticipirati budući procesi, događaji, akcije ili kretanja,
- to je instrument koji ima kompleksnu ulogu u procesu donošenja odluka.

U znanstvenoj i stručnoj literaturi opus radova o praktičnoj primjeni sustava poslovne inteligencije u jedinicama lokalne samouprave je vrlo skroman, a u Republici Hrvatskoj nema ni jednoga rada na tu temu, poznat autoru ove disertacije. U poslovnome sektoru Republike Hrvatske integriran je u velikim kompanijama poput Zagrebačke banke, VIPnet-a, Plive, Podravke, Privredne banke, Ine, Croatia osiguranja, Agrokora, Zagrebačke pivovare, Kraša i drugih dok se u javnome sektoru primjenjuje ograničeno samo u nekim institucijama.

U nekim se zemljama s razvijenim gospodarstvima iz našega okruženja ulažu kontinuirani napori na području upravljanja informacijama u javnome sektoru, pa u nekima od njih postoje središnji sustavi na nacionalnoj razini koji su zaduženi za taj posao. U kontekstu ovoga rada, za kvalitetnu obradu podataka koji se parcijalno generiraju u jedinicama lokalne samouprave i najčešće pohranjuju u baze podataka koje se koriste samo za statističku obradu u određene svrhe ili za potrebe izvješćivanja središnjih tijela ovlaštenih za statistiku u pojedinim segmentima (FINA, HZZO, DZS…) nameće se nužnost uspostave nacionalnoga sustava PI. Republika Hrvatska je stvorila zakonske pretpostavke za razvoj nacionalne informacijske infrastrukture kao sustava upravljanja informacijama i pristup svim javno dostupnim registrima preko središnje državnog portala na koje bi svi javni dionici, a poglavito politički menadžment, dobivali korisne informacije o stanju unutar svojih jedinica lokalne samouprave, ali i mogućnost analize učinkovitosti u odnosu na konkurenciju, odnosno druge jedinice iz usporedive skupine pomoću AOMP metode (*Slika 4-15*). Donošenje odluke ili suda o učinkovitosti upravljanja javnim resursima u realnome vremenu i za široki raspon zainteresiranih strana korespondira s postulatom o kvaliteti informacija prema kojemu vrijednost pojedine informacije razmjerno raste s brojem korisnika pomnožen brojem poslovnih područja u kojima ti korisnici djeluju (Liautaud, 2001.).

Za analizu omeđivanja podataka, kao osnovni alat za praćenje učinkovitosti upravljanja jedinicama lokalne samouprave potrebni su podatci o ključnim pokazateljima koje korisnik alata želi uzeti u obzir. Za potrebe istraživanja u sklopu ove radnje uzeti su raspoloživi statistički podatci koji se prikupljaju u različitim institucijama ili su dio akta JLSU-a, no analiza

učinkovitosti može se izraziti odabirom operativnih i financijskih vrijednosti provedbe proračuna te kroz cijeli niz pokazatelja operativnoga funkcioniranja.



Slika 4-15: Ciklus poslovne inteligencije

Aktualnost dobivenih rezultata ovisi o ažurnosti podataka i njihovoj aktualnosti, jer se u protivnome rezultati odnose na neko prošlo stanje koje u sadašnjim procesima upravljanja ne možemo promijeniti, ili drugim riječima samo agilne lokalne vlasti mogu reagirati na iznenadne promjene. Primjena koncepta poslovne inteligencije omogućuje javnim dionicima i menadžmentu korištenje samo onih informacija koje su im u određenome vremenu potrebne za donošenje poslovnih odluka i izvođenje zaključaka o učinkovitome upravljanju javnim resursima. Iz navedenih razloga analiza omeđivanja podataka, kao alat koji može unaprijediti proces upravljanja lokalnom samoupravom, jednostavno traži svoje uporište u IT sustavu koji nudi mogućnost prikupljanja, obrade i distribucije kvalitetnih informacija. Svaka jedinica lokalne

samouprave ili javna institucija koja svoje poslovanje podupire nekim informacijskim sustavom može koristiti i poslovnu inteligenciju.

Kao što je prikazano na *Slici 4-15* sustav PI predstavlja cikličnu aktivnost sastavljenu od šest osnovnih faza[57]:

a) planiranje i upravljanje ciklusom PI na nacionalnoj razini,
b) prikupljanje podataka u JLSU-u,
c) pohranjivanje podataka u temeljne registre,
d) obradba i analiza podataka,
e) generiranje ključnih pokazatelja na zahtjev korisnika i AOMP analiza,
f) distribucija informacija i analitičkih izvješća.

U evoluciji od poslovnih podataka do poslovnih informacija i znanja, svaki novi korak građen je na prethodnome. Stoga poslovna inteligencija predstavlja kontinuiran ciklus od trenutka projektiranja do implementacije i prilagodbe poslovnim procesima i zahtjevima korisnika. Faze unutar procesa poslovne inteligencije su međusobno povezane interaktivnim vezama s brojnim povratnim vezama.

Unatoč tomu postoji slijed aktivnosti u procesu koji je sastavljen od pet osnovnih, ali međusobno povezanih faza pri čem sljedeća može započeti tek kada prethodna uspješno završi. Ciklus počinje planiranjem i upravljanjem, odnosno postavljanjem ciljeva, potom slijedi prikupljanje podataka u temeljnim registrima koji se u sljedećoj fazi transformiraju, čiste i formatiraju prije pohrane u skladište podataka. Nakon toga su podatci spremni za analizu i modeliranje nekim od tehnika i alata PI (*AOMP*, *Data Mining*, *Dashboard*, *Online Analitical Processing…*), a u posljednjoj se fazi analize distribuiraju rezultati i analitička izvješća prema korisnicima. Taj proces teče kontinuirano paralelno s procesima upravljanja i generiranja novih podataka koji prolaze taj ciklus.

Struktura sustava poslovne inteligencije u lokalnoj samoupravi prikazana je na *Slici 4-16*. U strukturu je integrirana metoda analize omeđivanja podataka kao alat PI i poveznica između infrastrukture poslovne inteligencije i korisnika alata AOMP-a.

Kao što je prikazano na *Slici 4-16* gradovi i općine, kao dio osnovne infrastrukture PI, izvor su podataka koji nastaju u procesima javnoga upravljanja kao interni podaci (materijalno-financijski, knjigovodstveni, pravno-normativni…) i vanjski izvori koji se zasnivaju na

[57] Modificirano prema Ranjit, 2008.

podacima o javnim pokazateljima koji se odnose na lokalne zajednice (statistička izvješća o gospodarskim subjektima, HZZO, HZZ, FINA, HZJZ…).



Prilagođeno prema www.intechopen.com

Slika 4-16: AOMP u sustavu poslovne inteligencije

Podaci nastali u procesima unutar JLSU-a i vanjski podatci koji se odnose na gospodarsku aktivnost i standard građana koji se prikupljaju u nacionalnoj bazi podataka. S obzirom na to da baze podataka zasnovane na relacijskome modelu ne zadovoljavaju zahtjeve suvremenoga pristupa upravljanju zasnovanu na znanju, jer odražavaju samo ažurno stanje određenoga sustava, podaci se moraju prije korištenja pripremiti za korištenje i skladištenje.

Skladište podataka (eng. *Data Warehouse*) se puni sustavno uz pomoć ETL procesa (od eng. naziva *Extraction Transformation Loading*) kojima se ti podaci zahvaćaju, preoblikuju i unose iz jednoga ili više transakcijskih sustava u skladište podataka (Panian, 2003). ETL procesima se podaci u različitim formatima i iz različitih izvora filtriraju, preoblikuju (formatiraju), usklađuju i čiste prije smještanja u skladište podataka.

Na taj se način rješavaju problemi nepotpunosti, nekonzistentnosti i nepreciznosti izvornih podataka koji su zaprimljeni iz različitih datoteka nastalih u različitim JLSU-ima na različit način. Usklađivanje se podataka provodi da bi se izbjegla redundancija podataka jer, osim pojavljivanja istih podataka na različitim mjestima, oni mogu biti nedosljedni i različiti za istu pojavu. Ta je faza ključna za sve kasnije faze obrade podataka i predstavlja ključnu fazu u projektiranju i implementaciji PI sustava.

Tako specifično strukturirani i integrirani podaci u skladištu podataka omogućuju *ad-hoc* analize i kreiranje izvješća potrebnih za donošenje odluka. Strukturu skladišta podataka čine dva osnova dijela, a to su podaci i mehanizmi za njihovu manipulaciju. Dio skladišta podataka u kojem se nalaze podaci se sastoji od osnovnih podataka, u ovome slučaju transferiranih iz nacionalne baze podataka i agregiranih (izvedenih) višedimenzionalnih podataka. Pristup skladištu podataka mora biti osiguran svim javnim dionicima koji mogu samostalno kreirati upit i zatražiti određeni set karakterističnih pokazatelja upravljanja javnim resursima. Skladište je podataka ključni dio infrastrukture sustava poslovne inteligencije na koji se vezuje analiza omeđivanja podataka. Za modeliranje i analizu podataka kreirani su brojni alati koji se vezuju uz proizvođača ili određeni sektoru za koji je razvijen, a na *Slici 4-15* i *Slici 4-16* su istaknuti sljedeći: OLAP alati, rudarenje podataka, vizualizacijski alat - BSC i analiza omeđivanja podataka.

OLAP predstavlja skupinu analitičkih alata, čiji naziv dolazi od engleskoga naziva Online Analytical Processing, a u hrvatskom se jeziku najčešće prevodi kao online analitička obrada. Ta velika i najraširenija skupina PI alata kreirana je za multidimenzijsku analizu podataka na zahtjev širokoga raspona korisnika (klijenata). Online analitička obrada omogućuje korisnicima uvid u podatke na brz, konzistentan i interaktivan način kreirajući brojna i raznovrsna izvješća na osnovi informacija dobivenih analizom sirovih podataka kroz više dimenzija.

Rudarenje podataka (eng. *Data mining*) prema Panianu (2003.) se definira kao analitički proces pronalaženja zakonitosti u podatcima, u kojima se istražuju velike količine podataka u cilju pronalaženja konzistentnih oblika i odnosa varijabli te utvrđivanja vrijedi li pronađeno i na drugim skupovima podataka. Rudarenja podataka koristi koncepte, metode i tehnike različitih disciplina kao što su baze podataka, statistika i umjetna inteligencija. Uspješnost primjene rudarenja podataka ovisi prvenstveno o stručnosti i poslovnoj kompetenciji onih koji tumače dobivene rezultate. Upravo te osobe svojim znanjem i iskustvom mogu biti sposobne neki na izgled besmislen uzorak interpretirati na poslovno korektan i smislen način i pretvoriti ga u vrijednu informaciju.

Za što brže i jednostavnije tumačenje rezultata analize i sastavljanje izvješća kreirani su brojni vizualni alati kao što su tablice rezultata (eng. *scorecard*) i nadzorna ploča (eng. *dashboard*). Metoda uravnoteženih ciljeva (eng. *Ballanced scorecard)* opisana je detaljno u trećem poglavlju ovoga rada, a nadzorna ili radna ploča (eng. *dashboard*) je grafički alat koji omogućuje brzi i sažeti pregled rezultata za potrebe menadžmenta koji mora u što kraćem vremenu izvući što kvalitetnije informacije za donošenje operativnih odluka.

Primjena sustava poslovne inteligencije u lokalnoj samoupravi ima ispunjen osnovni preduvjet da je sustav poslovanja informatiziran jer danas svaka pa i najmanja jedinica lokalne samouprave svoje poslovanje podupire nekim informacijskim sustavom. No velik dio podataka u lokalnoj samoupravi još uvijek nije digitaliziran ili nije uopće unesen u neku bazu podataka. Informacijski sustavi su heterogeni čak ni unutar istih jedinica, a problem je utoliko veći što se obuhvat proširuje. Stoga se za pokretanje projekta poslovne inteligencije u iznesenome obliku treba riješiti niz tehničkih i organizacijskih (normativnih) pitanja na nacionalnoj razini. S obzirom na samu prirodu metode analiza omeđivanja podataka, kao osnovnoga menadžerskog alata, koja se zasniva na što većem broju jedinica uključenih u analizu kao preduvjeta uzimanja što većega broja karakterističnih pokazatelja, u sustav poslovne inteligencije je potrebno obuhvatiti što veći broj JLSU-a. Takav projekt zahtijeva nacionalnu strategiju i ozbiljan pristup upravljanju informacijama u javnoj upravi, što podrazumijeva integraciju informacijskih sustava JLSU-a u državnu informacijsku infrastrukturu i omogućavanje pristupa javno dostupnim informacijama što širem rasponu korisnika putem središnjeg državnog portala.

Praktična implementacija analize omeđivanja podataka i sustava poslovne inteligencije u širem, nacionalnom kontekstu zahtijeva što lakši pristup i dostupnost velikomu broju korisnika. Prije svega to se odnosi na politički menadžment koji upravlja javnim resursima, ali i svim javnim dionicima, odnosno poreznim obveznicima koji su glavni izvor prihoda JLSU.

Mogućnosti integracije AOMP-a i PI-a u lokalnu samoupravu su brojne, ali uzevši u obzir navedene zahtjeve, javni web-servis u sklopu državne informacijske infrastrukture daje najveće mogućnosti što će biti obrađeno u sljedećem poglavlju.

4.10.2. AOMP kao web-aplikacija za analizu efikasnosti/učinkovitosti

Ubrzani je razvoj informacijsko-komunikacijskih tehnologija utjecao na razvoj velikoga broja javnih servisa koji se mogu svesti pod nazivnik e-Uprava. Primjenom strategije e-Uprave omogućeno je kreiranje velikoga broja javnih servisa namijenjenih građanima, državnim tijelima i privredi. Inicijative e-Uprave uz upotrebu web-tehnologije usmjerene su na kvalitetniju, bržu i

sve dostupniju komunikaciju. Web-tehnologija podrazumijeva programska rješenja kojima se pristupa internetskim putem (koristeći Internet preglednik), a kojoj je moguće pristupiti s bilo kojega mjesta u bilo koje vrijeme. Navedeno opravdava mišljenje da upravo web-aplikacija može omogućiti praktičnu primjenu analize omeđivanja podataka svim zainteresiranim javnim dionicima jer čini dostupnim na jednome mjestu sve aplikacije i alate za analizu učinkovitosti upravljanja JLSU-a, a ujedno omogućava centralizirano upravljanje sigurnošću i pravima pristupa. Web-servis može omogućiti pristup aplikacijama i interaktivno korištenje metode AOMP-a i u sklopu sustava poslovne inteligencije ako se osim AOMP-a želi koristiti neki od alata PI-a navedenih u prethodnome poglavlju. Web-servisi su općeprihvaćeni i podržani od svih značajnijih proizvođača softvera, što govori u prilog njihovu značaju (Sharp, 2008.).

Analiza postojeće informacijske infrastrukture u Republici Hrvatskoj

Republika Hrvatska je u svojim strateškim dokumentima izrazila opredjeljenje za razvoj u informacijsko društvo[58] što je utjecalo na pokretanje nekoliko javnih web-servisa (HITRO HR, e-Gruntovnica, e-Katastar, Intrastat, e-Zdravstvo, FINA web-servisi, e-REGOS, e-Mirovinsko, e-plaćanje, e-Račun…). Iako je uspjeh i vijek primjene pojedinih javnih web-servisa bio kratak (npr. HITRO HR), njihov je razvoj sve intenzivniji i u ovome trenutku postoji nekoliko kvalitetnih javnih web-aplikacija koje omogućuju komunikaciju korisnika s tijelima državne uprave. Kao primjer dobre prakse treba istaknuti e-servis Porezne uprave za vođenje poslovnih knjiga, evidencija i izvješća koje su porezni obveznici dužni voditi u elektroničkome obliku[59], koji će biti ukratko opisan u nastavku.

Porezni obveznici, uz iznimku onih koji imaju do tri zaposlenika, preko jedinstvenoga obrasca poreza, prireza i doprinosa (JOPPD), mogu podnijeti svoje prijave koje se odnose na:

- prijavu poreza na dodanu vrijednost (ePDV),
- podnošenje konačnoga obračuna poreza na dodanu vrijednost (ePDV-K),
- podnošenje ID[60] obrasca (eID),
- podnošenje IDD[61] obrasca (eIDD),

[58] Vlada Republike Hrvatske je već 2003. godine usvojila Program e-Hrvatska 2007. godini koji je podijeljen u nekoliko područja: e-Uprava, e-Pravosuđe, e-Obrazovanje, e-Zdravstvo i e-Poslovanje.

[59] Pravilnik o obliku, sadržaju, roku i načinu dostave poslovnih knjiga, evidencija i izvješća koji se čuvaju u elektroničkom obliku, Narodne novine broj 59/09.

[60] ID obrazac za podnošenje izvješća o primicima od nesamostalnog rada (plaći i mirovini), porezu na dohodak i prirezu te doprinosima za obvezna osiguranja.

- podnošenje prijave poreza na dobit (ePD),
- podnošenje obračuna spomeničke rente (eSR),
- podnošenje obračuna članarine turističke zajednice (eTZ).

U okviru sustava e-Porezna korisnici također imaju mogućnost uvida u porezno-knjigovodstvenu karticu (ePKK) i mogućnost dostave druge dokumentacije vezane uz prijave poreza i dohotka s obzirom na to da ovaj web-servis umrežuje nekoliko državnih institucija: Ministarstvo financija, Poreznu upravu, REGOS i HZMO.

Podaci se u zajedničku bazu podataka dostavljaju putem Interneta u elektroničkome obliku čiji oblik, sadržaj, rok i način dostave poslovnih knjiga, evidencija i izvješća koji se čuvaju u elektroničkome obliku regulira Pravilnik („Narodne novine“ broj 59/09). Porezni su obveznici dužni na zahtjev poreznoga tijela dostaviti na uvid u obliku elektroničkoga zapisa sve datoteke, evidencije, izvješća i druge podatke koji izravno ili neizravno utječu na utvrđivanje porezne osnovice. Format i veličinu podataka korisnici moraju prilagoditi standardima koje propisuje prije spomenuti Pravilnik koji je donio ministar financija.

U kontekstu ovoga rada bitno je spomenuti da su normativno uređena sljedeća područja:

- koje podatke je korisnik obvezan dostaviti,
- koji se podaci (ne) smatraju elektroničkim zapisom,
- format i veličina datoteka i obveza prilagodbe standardima,
- sadržaj datoteka koje moraju sadržavati glavne baze podataka s podacima o pojedinačno nastalim poslovnim događajima i povezane baze podataka s podacima o izvornim dokumentima te pomoćne datoteke s drugim podacima,
- način dostave, medij za pohranu i sigurnosne postavke,
- obvezu opisa hardverske i softverske osnove te format i strukturu zapisa.

Porezni obveznici dostavljaju podatke u obliku baza podataka koje sadržavaju obvezna polja i koje su generirane prema zadanim standardima. Pri tome se polja s traženim podacima ne moraju nužno nalaziti u jednoj bazi podataka, nego ih sustav može kreirati spajanjem ili kombiniranjem pojedinih izvornih ili izvedenih baza podataka u kojima se nalaze podaci ili dijelovi podataka koji se traže. Porezna uprava utvrđuje pravila strukturiranja dokumenta pomoću XML shema

[61] *IDD* obrazac za podnošenje izvješća o drugom dohotku, obračunanom i uplaćenom porezu na dohodak i prirezu te doprinosima za obvezna osiguranja.

(eng. *EXtensible Markup Language)* prema šifrarniku kojim se određeni podatkovni sadržaj uokviruje odgovarajućim oznakama koje ga opisuju i imaju poznato ili lako shvatljivo značenje. Na taj način su svi podaci strukturirani prema istoj shemi, a korisnik nakon popunjavanja obveznih polja šalje XML datoteku na server porezne uprave, a provjeru ispravnosti i statusa datoteke obavlja sam kroz aplikaciju. Zbog različitih platformi i operacijskih sustava korisnika XML oznake su preduvjet za njihovo čitanje, obradu i interpretaciju na serveru porezne uprave.

U toj su web-aplikaciji uspješno implementirani svi elementi koji čine osnovu za izradu koncepta web-servisa za analizu učinkovitosti upravljanja jedinicama lokalne samouprave u Republici Hrvatskoj metodom analize omeđivanja podataka.

Za izradu koncepta web-servisa potrebno je utvrditi opseg i vrstu podataka koje gradovi, odnosno JLSU, prema postojećoj zakonskoj regulativi moraju dostavljati središnjim državnim tijelima i institucijama, kao izvor unutarnjih podataka i, s druge strane, koji su podaci o gospodarskome razvoju i standardu građana raspoloživi kao vanjski podaci.

Zakonska regulativa i obveze dostavljanja podataka

Zakonom o sustavu državne uprave[62] i Zakonom o općem upravnom postupku[63] propisana je obveza za službenike u javnim službama da po službenoj dužnosti moraju pribaviti podatke o kojim državna tijela vode službene evidencije. Obvezu prikupljanja i dostavljanja podataka javne (lokalne) uprave reguliraju zakonske odredbe za svako područje zasebno. Na primjer, prema Zakonu o fiskalnoj odgovornosti[64] i Zakonu o Proračunu[65] jedinice lokalne samouprave su dužne dostavljati središnjem državnom tijelu proračun i izvješće o izvršenju proračuna u kojem je, prema zadanoj metodologiji, prikazana struktura prihoda i rashoda. Tako su podaci o fiskalnom potencijalu gradova, za potrebe istraživanja u sklopu ove radnje, prikupljeni iz službenih glasila gradova jer ih Ministarstvo financija nakon prikupljanja ne objavljuje niti nudi mogućnost pristupa.

Osim financijskih pokazatelja JLSU su dužne dostavljati podatke o aktivnostima usmjerenima na razvoj poduzetničke infrastrukture i postojećim gospodarskim kapacitetima u Jedinstveni registar poduzetničke infrastrukture koji vodi Ministarstvo poduzetništva i obrta.

[62] „Narodne novine“ broj 150/11

[63] „Narodne novine“ broj 47/09

[64] „Narodne novine“ broj 139/10 i 19/14

[65] „Narodne novine“ broj 87/2008 i 136/12

Jednako tako dužne su voditi i registar potrošnje energenata u zgradama javne namjene (ISGE[66]) u kojem su specificirane i opisane sve građevine javne namjene u vlasništvu ili pod upravom JLSU. Neki gradovi i općine vode vlastite baze imovine koje klasificiraju imovinu prema namjeni i razini angažiranosti (npr. BIG Grada Varaždina) kao izvrsna osnova za gospodarenje imovinom. Iz navedenoga se može zaključiti da prikupljanje podataka i obveze izvješćivanja prema zadanim standardima već postoji u određenim segmentima javne uprave, ali prikupljeni podaci nisu sistematizirani, formatirani ni dostupni za daljnju upotrebu.

Iako se iz iznijetog može zaključiti da u Republici Hrvatskoj postoje razne baze podataka i e-servisi za građane i pravne subjekte koji nisu interoperabilni[67], izvješća pravnih subjekata su u velikoj mjeri digitalizirana i u XML verziji se dostavljaju različitim institucijama (FINA, Porezna Uprava, HZZO, HZMO, HZZ…), što nudi gotovo neograničene analitičke mogućnosti.

Nedavno donesenim Zakonom o državnoj informacijskoj infrastrukturi[68] stvorene su pravne pretpostavke za razvoj jedinstvenog informacijskog sustava na području Republike Hrvatske koji bi trebao doprinijeti tranziciji državne uprave prema *e-governmentu*. Do donošenja ovog zakona u Republici Hrvatskoj nije postojala obveza povezivanja javnih registara kao osnovne pretpostavke za izgradnju nacionalnog informacijskog sustava. No ovim se zakonom predviđa ustrojavanje nacionalne informacijske infrastrukture koja će omogućiti pružanje e-usluga svim javnim dionicima prema određenim standardima. Pri tome, informacije koje javni sektor pruža korisnicima trebale bi biti standardizirane i strukturirane tako da ih svi korisnici, bez obzira kojim komunikacijskim kanalom pristupaju, mogu koristiti prema korisničkim razinama.

Zakon o državnoj informacijskoj infrastrukturi osim obveza nadležnih tijela iz javnog sektora vezano uz uspostavu sustava, utvrđuje i uspostavu te upravljanje sustavom javnih registara, definira uvjete koje državna informacijska infrastruktura mora osigurati u odnosu na javne registre, kao i korištenje zajedničke osnovice za sigurnu razmjenu podataka unutar sustava državne informacijske infrastrukture, zajedničkog sustava identifikacije i autentifikacije, jedinstvene točke interakcije s građanima i drugim korisnicima.

Za implementaciju sustava poslovne inteligencije i analitičkog alata AOMP, posebno je važna odredba koja regulira ustrojavanje temeljnih registara kao dijela središnjeg državnog portala na kojem će biti objedinjene sve informacije (obrađeni podaci) koje se odnose na javni sektor. Na taj će se način osigurati interoperabilnost javnih registara i informacijskih sustava koji se odnose

[66] ISGE sustav je internetska aplikacija za nadzor i analizu potrošnje energije i vode u zgradama javnoga sektora.

[67] Interoperabilnost – sposobnost različitih sustava da djeluju jedinstveno

[68] „Narodne novine“ broj 92/14 od 18. 07.2014. godine

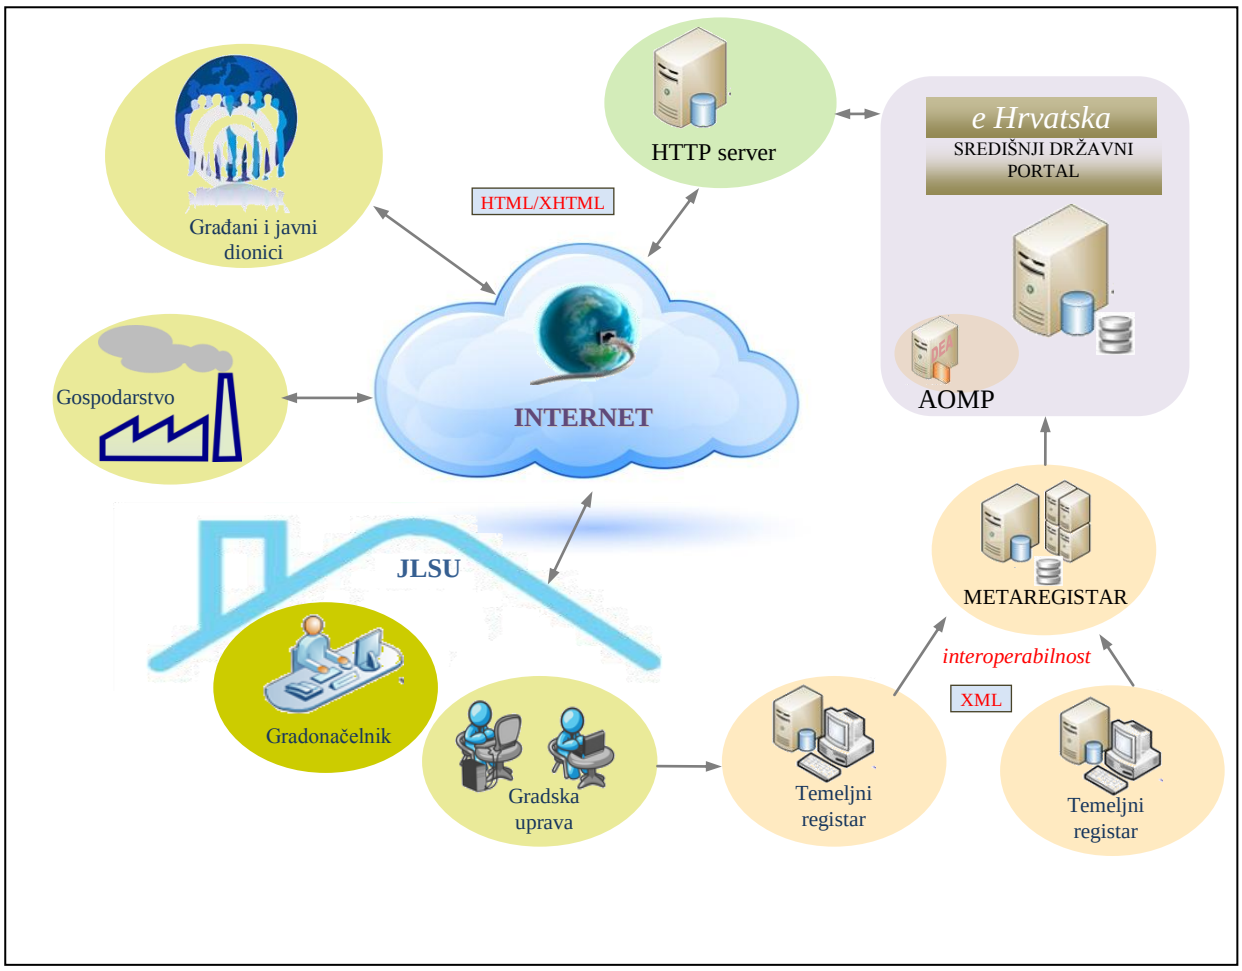
na sustav lokalne samouprave, koja je predmet istraživanja u ovom radu. Javni registri će biti smješteni u podatkovnim centrima kojima će upravljati pravna osoba, dok će središnji državnim portal biti u nadležnosti središnjeg tijela državne uprave, zaduženog za poslove e- Hrvatske.
Ovi zakonski okviri omogućavaju uključivanje analize učinkovitosti upravljanja lokalnom samoupravom u Republici Hrvatskoj kao jednog od projekata koji će biti dio državne informacijske infrastrukture.

Rukovodeći se zakonskim odredbama i primjerom e-Porezne uprave, za ustrojavanje web-servisa za analizu učinkovitosti upravljanja JLSU-om, Zakon predviđa donošenje provedbenih akata kojima će biti obuhvat obveznika dostave informacija i utvrditi oblik i sadržaj podataka te rok i način njihove dostave u elektroničkome obliku te minimalne tehničke uvjete koje korisnik mora ispunjavati.

Slika 4-17 prikazuje organizacijsku strukturu informacijskog sustava u koji su uključeni temeljni registri kao javni registri u kojima se prikupljaju autentični podaci, a njihovu interoperabilnost omogućiti će transformacija podataka u informacije u metaregistrima, kao preduvjet njihovog korištenja na središnjem državnom portalu.
Putem središnjeg državnog portala moći će se pristupiti svim javno dostupnim informacijama koje će sadržavati i informacije bitne za ocjenu učinkovitosti upravljanja JLSU-om. Gradovi su dio nacionalne informacijske infrastrukture koja generira ključne podatke koji nastaju u procesima javnoga upravljanja kao interni podaci (materijalno-financijski, knjigovodstveni, pravno-normativni…) koji se prikupljaju u temeljnim registrima (FINA, HZZO, HZMO, PU,…).
Za pristup podacima predviđeno je postojanje elektroničkog pretinca, nacionalnog identifikacijskog i autentifikacijskog sustava kao i elektroničke osobne karte. Na taj se način mogu definirati razine pristupa koje će omogućiti i samostalno kreiranje upita i izvješća nakon analize.

Korisnik web-servisa za analizu učinkovitosti upravljanja lokalnom samoupravom će moći na korisničkom sučelju, sa unaprijed standardiziranim upitima, odabrati ključne informacije na temelju kojih želi utvrditi učinkovitost upravljanja javnim resursima.

Kreiranje upita odabirom karakterističnih pokazatelja upravljanja javnim resursima iz skupa dostupnih podataka u središnjem državnom portalu, kao skladišta podataka, korisnik će moći utvrditi učinkovitost upravljanja javnim resursima upravo u domeni koja odražava njegov interes. Pristup putem web-aplikacije mora biti osiguran svim javnim dionicima prema unaprijed određenim razinama korisničkoga pristupa.



Slika 4-17: Shema web-servisa za AOMP

Osim javnih dionika, interes za ustrojavanja i korištenje javnog web servisa imaju gradonačelnici (župani) i načelnici, koji su u ovome radu promatrani kao politički menadžeri koji donose bitne odluke DO i čije se stručne kompetencije izravno odražavaju na učinkovitost upravljanja. Oni moraju biti aktivni sudionici i inicijatori u implementaciji sustava kroz poslovne procese na svim razinama unutar JLSU. Upravo politički menadžment treba definirati ključne pokazatelje koji trebaju biti uključeni u proces prikupljanja i obrade kako bi poslužili u analizi jer oni mogu identificirati najvažnije pokazatelje prema kojima se žele usporediti s jedinicama u okruženju. Kao što je u uvodnim poglavljima bilo izneseno, zbog inertnosti i otpora prema promjenama u javnoj upravi, a bez aktivnoga sudjelovanja i preuzimanja inicijative od strane čelnika, implementacija neće uspjeti. Donositeljima odluka u JLSU analiza omeđivanja podataka kao javna web-aplikacija može omogućiti generiranje informacija bitnih za učinkovito upravljanje javnim resursima, što je i istaknuto kao jedan od ciljeva ove radnje. Praktična primjenjivost

AOMP-a kao menadžerskoga alata, bit će utoliko veća ukoliko će se povećati ažurnost podataka, njihov opseg i raznovrsnost u smislu izvora i broj korisnika s kojima se može obaviti benchmarking, a to će osigurati državna informacijska infrastruktura koja treba funkcionirati po principima poslovne inteligencije, a ulaskom Hrvatske u Europsku uniju stvorena je mogućnost uključivanja u analizu i gradova iz šireg okruženja.

S druge strane svim javnim dionicima (građani, gospodarstvo, državna tijela i institucije…) AOMP može omogućiti procjenu kvalitete političkoga menadžmenta i nadzor korištenja javnih resursa. Upotrebom metode analize omeđivanja podataka kao općeprihvaćenoga javnog web-servisa, sagledavanjem kroz iznesene mogućnosti i prikazanu funkcionalnost same metode, nedvojbeno se može poboljšati učinkovitost upravljanja javnim resursima.

5. ZAKLJUČAK

Osnovni cilj istraživanja, u sklopu ove doktorske disertacije, bio je usmjeren na utvrđivanje relativne učinkovitosti upravljanja velikim gradovima u Republici Hrvatskoj metodom omeđivanja podataka na osnovi ekonomskih pokazatelja uz osnovnu pretpostavku da se konkurentske prednosti gradova ne zasnivaju isključivo na fizičkim resursima već na ljudskome znanju i kompetencijama političkoga menadžmenta.

U poglavlju 4.6. je utvrđena relativna učinkovitost upravljanja velikim gradovima u Republici Hrvatskoj metodom analize omeđivanja podataka na temelju ekonomskih pokazatelja. Analizirajući osnovne nadležnosti gradova, kao jedinice lokalne samouprave, odabrana su dva diskrecijska ulaza/resursa: prirez i porez na dohodak po stanovniku, komunalni doprinos i druge naknade po stanovniku, koji se u procesima upravljanja transformiraju u izlaze/učinke izražene stopom nezaposlenosti, prosječnim plaćama i investicijama u gospodarstvu po zaposlenom. Dva kontrolna (nediskrecijska) ulaza su korištena u dodatnoj analizi u cilju potvrđivanja osnovne pretpostavke ove disertacije da se konkurentske prednosti gradova ne zasnivaju na fizičkim resursima već na ljudskome znanju i kompetencijama političkoga menadžmenta.

U analizi su bila korištena dva modela AOMP-a usmjerena k ostvarivanju rezultata sa zadanom količinom resursa (IU CCR i IU BCC).

Prosječna relativna učinkovitost upravljanja velikim hrvatskim gradovima iznosi 87,67% što znači da u prosjeku lokalni politički menadžment mora postizati 14% bolje rezultate s istim resursima da bi bio učinkovit.

Od ukupne populacije (15) velikih gradova u Republici Hrvatskoj šest gradova definira granicu učinkovitosti i kao primjeri dobre prakse upravljanja predstavljaju referentni skup za neučinkovite gradove.

Za neučinkovite gradove utvrđeni su izvori neučinkovitosti prema odabranim pokazateljima i ciljane vrijednosti ključnih pokazatelja koje moraju postići za projekciju na granicu učinkovitosti.

Najveći utjecaj na loše rezultate neučinkovitih gradova imala je visoka stopa nezaposlenosti i niske investicije po zaposlenome.

Za svaki neučinkoviti grad određeni su referentni gradovi kao primjeri dobre prakse (*benchmarking*) koji bi s dodijeljenim težinama neučinkovitoga grada zadržali svoju učinkovitost. Prema frekvenciji pojavljivanja u skupu referentnih gradova najučinkovitija je bila uprava grada Vinkovaca koja je uzorna za sve neučinkovite gradove.

Neučinkovite gradske vlasti moraju poduzimati aktivnosti koje će utjecati na smanjenje stope nezaposlenosti, poticati gospodarske aktivnosti i utjecati na kvalitativne promjene privlačenjem djelatnosti koje mogu osigurati višu razinu ostvarivanja dohotka po zaposlenome.
Analiza rezultata dobivenih metodom AOMP ukazuje da ne postoji povezanost između odnosa vrijednosti empirijskih podataka odabranih pokazatelja i same učinkovitosti upravljanja. Iz navedenoga proizlazi zaključak da menadžment koji donosi odluke samo na osnovi vrijednosti određenoga pokazatelja može biti u potpunoj zabludi i odlučivati na osnovi krivih spoznaja.

Analiza omeđivanja podataka generira informacije i nudi interpretaciju rezultata koji su bitni lokalnomu političkom menadžmentu u procesu upravljanja javnim resursima i mogu pozitivno utjecati na poboljšanje učinkovitosti upravljanja. S obzirom na to da metoda AOMP maksimalizira učinke upravljanja, određivanjem optimalnih težina ključnih performansi, može se koristiti za vanjsko vrjednovanje i procjenu kvalitete političkoga menadžmenta. Navedeni rezultati istraživanja i njihova interpretacija s korisničke perspektive u poglavlju 4.6 daju odgovor na hipotezu H2.

Iako nije utvrđena veza između (dis)kontinuiteta vlasti i relativne učinkovitosti upravljanja, AOPM analizom prozora (*window*) utvrđena je najveća učinkovitost u godini nakon izbora (druga godina mandata), što se može protumačiti političkim pragmatizmom koji podređuje ostvarivanje dugoročnih razvojnih politika kratkoročnim političkim ciljevima koji u prvome planu imaju osiguranje kontinuiteta vlasti.

Usporedbom relativne učinkovitosti upravljanja gradovima u RH s dvije varijante ulaza (diskrecijski/nediskrecijski) s pokazateljima ekonomskoga razvoja određenoga grada, iskazanoga indeksom ekonomske efikasnosti i indeksom razvijenosti, potvrđuje pretpostavke da učinkovitost upravljanja primarno ovisi o kompetencijama lokalnih vlasti u odnosu na raspoložive resurse kojima one upravljaju. Ova tvrdnja proizlazi iz osnova sistemskog pristupa organizaciji prema kojem se učinkovitost (postizanje ciljeva) postiže transformacijom inputa u outpute pri čemu se inputi sastoje od menadžerskog znanja i potrebnih resursa (Buble, 2000). Navedeni rezultati daju odgovor na hipotezu H1.

Veći stupanj povezanosti varijabli relativne učinkovitosti s nediskrecijskim ulazima i pokazatelja ekonomske razvijenosti gradova, u odnosu na istu s diskrecijskim ulazima, ukazuje na mogućnost usmjeravanja AOMP-a odabirom karakterističnih pokazatelja pri čem veći stupanj diskrecije ulaza pozitivno utječe na doprinos ljudskih potencijala na rezultat, čime je dat odgovor i na hipotezu H IV.

Analiza omeđivanja podataka korisna je metoda za usporednu analizu jedinica lokalne samouprave i drugih organizacija u javnome sektoru koje koriste iste ulaze i proizvode iste učinke, a međusobno se razlikuju po razini resursa kojima raspolažu i razini aktivnosti u procesima transformacije. No da bi AOMP-a postao praktičan menadžerski alat u javnoj upravi, potrebno je osigurati pristup širokomu rasponu konzistentnih i ažurnih podataka o ključnim pokazateljima. Premda u Republici Hrvatskoj ne postoji jedinstven i organiziran način prikupljanja podataka koji se odnose na rad lokalne samouprave, već se isti vode na različitim mjestima i u različitim formatima, a dio podataka izvan sustava lokalne samouprave se prikuplja na različitim mjestima (FINA, PU, HZS, HGK, HZMO, HZZO…) potrebno je normativno i organizacijski pozicionirati sustav za prikupljanje i obradbu podataka na nacionalnoj razini po modelu sustava poslovne inteligencije u kojem će AOMP biti jedan od analitičkih alata.
Javni web-servis u koji će biti implementirani elementi sustava poslovne inteligencije s metodom analize omeđivanja podataka kao analitičkim alatom, može postati značajan čimbenik u unaprjeđenju sustava upravljanja javnom upravom i rezultirati povećanjem učinkovitosti upravljanja te omogućiti objektivno vanjsko vrjednovanje, kao što je pretpostavljeno hipotezom H III.

Na osnovi provedenoga istraživanja i prikazanih rezultata smatra se da analiza omeđivanja podataka u lokalnoj samoupravi i u drugim organizacijama neprofitnoga sektora, može biti vrlo snažna podrška odlučivanju i upravljanju. Prihvaćanje AOMP-a od strane nositelja lokalnih vlasti pozitivno će utjecati na procese planiranja i donošenja odluka i na taj način povećati konkurentnost lokalne samouprave u Republici Hrvatskoj.

S obzirom na to da u Republici Hrvatskoj nije uveden ni jedan model ocjene učinkovitosti lokalne samouprave, očekuje se da će ovaj rad doprinijeti razvoju nacionalnih metodoloških okvira za praćenje i ocjenjivanje upravljanja javnim sektorom u Republici Hrvatskoj.

Rezultati istraživanja i znanstvene spoznaje o mogućnosti usmjeravanja istraživanja odabirom ključnih performansi doprinijet će razvoju metodike AOMP-a.

Nedostatak raspoloživih podataka, njihova sistematizacija i pretvorba u kvalitetne informacije bitna su ograničenja u provedbi analize učinkovitosti upravljanja lokalnom samoupravom u Republici Hrvatskoj. Stoga je u ovome radu obrađena mogućnost implementacije AOMP-a u sustav poslovne inteligencije koji omogućuje prikupljanje, skladištenje i analiziranje podataka bitnih za donošenje odluka.

S obzirom na nastojanje da se AOMP prikaže kao praktičan i primjenjiv alat u sklopu ove radnje ponuđen je koncept javnoga web-servisa koji omogućuje praktičnu implementaciju analize omeđivanja podataka i sustava poslovne inteligencije na nacionalnoj razini.

Prema iznijetom, u ovoj su disertaciji ostvareni ciljevi istraživanja i dobiveni odgovori na postavljene hipoteze.

dr. sc. Tomislav Bogović

LITERATURA

1. Afonso, A., Aubyn, M., S.: *Non-Parament Approaches to Education and Health Efficiency in OECD Countries*, Journal of Applied Economics, 8, 227-246, 2005.
2. Afonso, A., Fernandes, S.: *Assessing and Explaining the Relative efficiency of Local Government*, The Journal of Socio-Economics 37, 1946–1979, 2008.
3. Antić, Lj.*: Dizajniranje sistema mjerenja performansi u gradskoj upravi*, Ekonomske teme, Niš, 5, 167-174, 2005.
4. Antić, T.: *Centralna uprava i lokalna samouprava u Hrvatskoj: decentralizacija i demokracija*, Fiskalna decentralizacija u Hrvatskoj, Institut za javne financije, Zagreb, 2002.
5. Asmild, M., Paradi, J. C., Aggarwall V., Schaffnit, C.: *Combining DEA Window Analysis with the Malmquist Index Approach in a Study of the Canadian Banking Industry*, Journal of Productivity Analysis, 21, 67-89, 2004.
6. Bahovec, V., Neralić, L.: *Relative efficiency of agricultural production in county districts of Croatia*, Mathematical Communications – Supplement, 1, 111 – 119, 2001.
7. Baily, J. S.: *Local Government Economics, Principle and Practice*, Macimillian Press Ltd., London, 1999.
8. Bartik,T., J.: *Local economic Development Policies*, The W.E. Upjohn institute for Employment Research, Michigan, 2, 2003.
9. Begg, I.: *Cities and Competitiveness*, Urban studies, 36, 795-809, 1999.
10. Bennett, J., R.: *Local Government in Post-socialist Cities, Discussion Papers*, No. 2, Local Government and Public Service Reform Initiative, Budapest, 1997.
11. Blair, J., P.: *Local Economic Development: Analysis and Practice*, SAGE Publications, Thousand Oaks, 1994.
12. Blakely, E., Bradshaw, T.: *Planning Local Economic Development: Theory and Practice*, 3rd ed. SAGE, Incorporated, 2002.
13. Boyne, G., A.: Competitive Tendering In Local Government: A Review of Theory and Evidence, Public Administration, 76, 4, 695 – 712, 1988.
14. Buble, M.: Management, Ekonomski fakultet Split, 2000
15. Byrnes, P., Strobeck , J.: *Efficiency Gains from Regionalization: Economic Development in China Revisited*, Socio-Economic Planning, 34, 141-154, 2000.
16. Camagni, R.: The city as a milieu: applying GREMI's approach to urban evolution, Revue d' Economie Régionale et Urbaine, 3, 591-606, 1999.
17. Casson, M.: *Analysing Regional Business Networks: An Economic Perspective*, University of Reading, Department of Economics Working Paper, 2002.

18. Castells, M.: *European Cities, the Informational Society and Global Economy*, Journal of Economy and Social Geography, 84, 558 – 578, 1993.
19. Charnes, A., Cooper, W., Shanling, L.: *Using data envelopment analysis to evaluate efficiency in the economic performance of Chinese cities*, Socio-Economic Planning Sciences, 23, 325-344, 1989.
20. Chen, Y., Chin, Y., Huang C.: *Government Administration Efficiency and Economic Efficiency for 23 Districts in Taiwan*, International Journal of Organizational Innovation, 2 (4), 1-263, 2010.
21. Cooper, W.W., Seiford, L.M., Zhu, J.: *Data Envelopment Analysis; History, Models and Interpretations*, International Series in Operations Research & Management Science, 71, 1-39, 2004.
22. Cooper, W.W., Seiford, L.M., Tone, K.: *Introduction to Data Envelopment Analysis and its Uses: With DEA-Slover Softver and References*, New York: Springer, 2005.
23. Cooper, W.W., Seiford, L.M., Zhu, J.: *Handbook on Data Envelopment Analysis*, Second Edition,Springer Science&Business Media, New York, 2011.
24. Cooper, W.W.,Ray, S.: *A response to M. Stone: How not to measure the efficiency of public services (and how one might)*, Journal of the Royal Statistical Society, 171, 443-448, 2008.
25. Čapkova, S.: *Local Government and Economic Development*, Open Society Institute, Budapest, 3-19, 2005.
26. Deller, S., Rudnicki, E.: *Managerial efficiency in local government: Implications on jurisdictional consolidation*, Public Choice, 74, 221-231, 1992.
27. Drake, L., Simpe, R.: *X-efficiency and scale economies in policing: a comparative study using the distribution free approach and DEA*, Applied Economics, 34, 1859-1870, 2002.
28. Eckardt, S.: *Political Accountability, Fiscal Conditions, and Local Government Performance – Cross Sectional Evidence from Indonesia*, Institute of Local Public Finance, New York, 2008.
29. Eisinger, P.K.: *The Rise of the Entrepreneurial Stat*e, University of Wisconsin Press, Madison, 1988.
30. Emrouznejad, A., Parker, B.R., Travers, G.:, Journal of Socio-Economics Planning Sciences, 42 (3), 151-157, 2008.
31. Engel, C.: *Common Assessment Framework: The state of affairs, Eipascop*e, 1, 35-39, 2003.
32. Fajt, O.: *Uravnoteženi sistem kazalnikov v podjetih in v državni upravi* , Specijalističko delo, Ekonomski fakultet Ljubljana, 2005.
33. Farrell, M., J. :*The measurement of productive efficiency*, Journal of the Royal Statistical Society. Series, 253-290, 1957.

34. Feiock, R.,C., Kim, J-H.: *Form of Government, Administrative Organization, and Local Economic Development Policy*, Journal of Public Administration Research and Theory, 11 (1), 29-50, 2001.
35. Foley, P., Hutchinson, J., Kondej, A., Mueller, J.: *Economic development in Poland: a local perspective*, European Business Review, 96 (2), 23 – 31, 1996.
36. Fu-Lai Yu, T.: *A new perspective on the role of the government in economic development: Coordination under uncertainty*, International Journal of Social Economics, 27,994 – 1013, 2000.
37. Gavrilović, V.: *Unapređenje sistema upravljanja kvalitetom primenom koncepta samoocjenjivanja*, The TQM Magazine, 35 (1-2), 85-91, 2007.
38. George, C., F., Cooper, A. Douglas: I*mplementing the EFQM excellence model in a local authority*, Menagerial Auditing Journal, 18 (2), 122-127, 2003.
39. Geys, B., Heinemann, F., Kalb, A.:*Value for Money? Measuring German Local Government Efficiency*, Wissenschaftszentrum Berlin, 2007.
40. Goldsmith, M., Larsen H.: *Local Political Leadership: Nordic Style*, International Journal of Urban and Regional Research, 28, 121 – 133, 2004.
41. Guthrie, J., English, L.: *Performance information and program evaluation in the Australian public sector*, International Journal of Public Sector Management, 10, 1997.
42. Haas, D., Kocher, M., G., Sutter, M.: *Measuring Efficiency of German Football Teams by Data Envelopment Analysis*, Institute of Public Economics, University of Innsbruck, 2001.
43. Halkos, G., Tezeremes, N.: *A DEA approach to regional development*, University of Thessaly, 2005.
44. Hayek, F.: *Put u ropstvo*, Kruzak, Zagreb, 2001.
45. Henderson, J. V.: *The Effects of Urban Concentration on Economic Growth*, NBER, Brown University, 2000.
46. Holzer, M.: *Literature Review and Analysis Related to Measurement of Local Government Efficiency*, SPAA, Rutgers University, 2009.
47. Hood, C.: *The „New Public Management" int he 1980s: Variations on a Theme*, Accounting Organization and Society, 93 - 109 , 1995.
48. Huges, P. A., Edwards, N.:, *Leviathan Vs. Lilliputian: A Data Envelopment Analysis Of Government Efficiency* Journal of Regional Science, 649-669, 2000.
49. Hunjak, T., Jakovčević, D.: *Višekriterijski modeli za rangiranje i uspoređivanje banaka*, Zbornik Ekonomskog fakulteta u Zagrebu, 1, 43-60, 2003.

50. Hunjet, D.: *Efikasnost poslovnih sredstava hrvatske industrije po regijama*, magistarski rad, Ekonomski fakultet Zagreb, Zagreb,1998.
51. Jafarov, E., Gunnarson, V.: *Učinkovitost državne socijalne potrošnje u Hrvatskoj*, Financijska teorija i praksa, Zagreb, 32 (3), 291-322, 2008.
52. Javorović, B., Bilandžić, M.: *Poslovne informacije i business intelligence*, Golden marketing – Tehnička knjiga, Zagreb, 2007.
53. Jermić, I., Vujčić, B.: *Efficiency of banks in Croatia: a DEA approach*, Comparative Economic Studies, 169 – 193, 2002.
54. Johanson, U., Skoog, M., Backlund, A., Almqvist, R.*: Balancing dilemmas of the balanced scorecard*, Accounting, Auditing & Accountability Journal, 842- 857, 2006.
55. Kaplan R., Norton D.: *Having problems with your Strategy? Then Map it*, Harvard Business Review, 5, 2000.
56. Kaplan, R., Norton, D.: *Transforming the Balanced Scorecard from Performance Measurement to Strategic Management: Part I,* Accounting horizons, 1, 87 – 109 , 2001.
57. Kaplan, R.: *Strategic Performance Measurement and Management in Nonprofit Organizations*, Nonprofit Management & Leadership, 353 – 370, 2001.
58. Karakazis, J., Thanassoulis, E.: *Assessing the effectiveness of regional development policies in Northern Greece using Data envelopment analysis*, Socio-Economic Planning Sciences, 32 (2), 123-137, 1998.
59. Knagjuan, L., Zheng Z.:, *The Analysis on Total Factor Productivity of Cities in China* Sydney Institute of Language and Commerce, Shanghai University, 175 – 180 , 2006.
60. Knox, P.: *World cities in a world system*, Cambridge University Press, Cambridge, 3-21, 1995.
61. Kovač, P.: *Integracija modela odličnosti EFQM in sistema uravnoteženeih kazalnikov BSC v javni upravi*, Uprava, Ljubljana, 57-80, 2008.
62. Kovač, P.: *Skupni ocenjevalni okvir (CAF) kot most do globalizacije v javnih upravah Evropske unije*, Interntni portal kakvosti, učitano na: www.mju.gov.si/fileadmin/mju.gov.si/Kovac-DP-nov03.doc], 13.9.2009.
63. Kresl, P., Singh, B.: *Competitiveness and the urban economy: twenty-four large US metropolitan areas*, Urban Studies, 36, 1017 – 1027, 1999.
64. Liautaud, B.: *eBusiness Intelligence: Turning Information into Knowledge into Profit*, McGraw-Hill, New York, 2001.
65. Loikkanen, H., A., Susiluoto, I.: *Cost Efficiency of Finish Municipalities in Basic Service Provision 1994-2002*, HECER, 96, 2006.

66. Lončarević, M.: *Sustav uravnoteženih ciljeva u funkciji uspješnosti poslovanja hrvatskih poduzeća*, Ekonomski pregled, 57 (1-2), 97-129, 2006.
67. Lovell, C., A.: *Linear programming approaches to the measurement and analysis of productive efficiency*, TOP, 175-248, 1994.
68. Lubina, H.: *Contextualizing Local Economic Development for Developing Countries,* Pakistan Institute of Development Economics, 7959, 1 -31, 1998.
69. Luetić, A., Šerić, N.: *Business Intelligence u funkciji upravljanja nabavnim lancem*, Ekonomski fakultet, Split, 167-184, 2009.
70. Madon, S., Sahay, S.: *Cities in the Developing World*, A Network of Flows Information Technology & People, 14 (3), 2001.
71. Marković, M., R.: *Managing the organizational change and culture in the age of globalization,* Journal of Business Economics and Management, 9 (1), 3 – 11, 2008.
72. Martell, C.R., Guuess, G.M.: *Development of local Government Debt Financing Markets*, Public Budgeting & Finance, 88 – 119, 2006.
73. Martić, M., Novaković, M.S., Baggia, A.: *Data Envelopment Analysis – Basic Model and their Utilization*, Organizacija, Maribor, 42, 37 – 43, 2009.
74. Martić, M., Savić G.: *An Application of DEA Comparative Analysis and Ranking of regions in Serbia with Regards to Social-Economic Development*, European Journal of Operational Research, 129, 344 – 355, 2001.
75. Mastmarco, C., Woitek, U.: *Public Infrastructure Investment and Efficiency in Italian Regions*, Journal of Productivity analysis, 57 – 65, 2006.
76. Maudos, J., Pastor, J.M., Serrano, L.: *Efficiency and productive specialization: an application to the Spanish regions*, Regional Studies, 829-824, 2000.
77. Mawson, J.: *Regional governance in England: past experience, future directions?,* International Journal of Public Sector Management, 20 (6), 548 - 566, 2007.
78. Mayer – Stamer, J.: *Governance and Territorial Development*, Mesopartner, Duisburg, 7, 2004.
79. Moesen, W.: *The need performance auditing in the public sector and the best practice frontier*, European journal of law and economic, 263 - 274, 1994.
80. Moore, A., Nolan, J., Segal G.: *Putting Out The Trash: Measuring Municipal Service Efficiency in U.S. Cities*, Urban Affairs Review, 41, 237-259, 2005.
81. Musa, A.: *Europski upravni prostor - približavanje nacionalnih uprava,* Hrvatska javna uprava, 6 (1),123-154 , 2006.

82. Nanus, B., Dobbs, S., M.: *Leaders who Make a Difference: Essential Strategies for Meeting the Nonprofit Challenge*, Jossey-Bass Publications, San Francisco, 1999.
83. Neralić, L.: *O nekim primjenama analize omeđivanja podataka u bankarstvu*, Ekonomija, 3, 493-521, 1996.
84. Nijkamp, P., Suzuki, S.: *A Generalized Goals-achievement Model in Data Envelopment Analysis: an Application to Efficiency Improvement in Local Government Finance in Japan*, Spatial Economic Analysis, 4(3), 249-274, 2009.
85. Niven, P. R.: *Balanced Scorecard Diagnostics, Maintaining Maximum Perfo*rmance, John Wiley & Sons, New Jersey, 2003.
86. Niven, P. R.: *Balanced Scorecard Step-by-step*, John Wiley & Sons, New York, 2002.
87. Oates, W.: *Fiscal decentralization and economic development*, National Tax Journal, 237 – 243, 1993.
88. Palmer, A.: *Performance measurement in local government*, Public Money and Management, 31 – 36, 1993.
89. Panian, Ž., Klepac, G.:*Poslovna inteligencija*, Masmedia, Zagreb, 2003.
90. Petak, Z., Kasapović, M., Lalić, D.: *Lokalna politika u Hrvatskoj*, Fakultet političkih znanosti Zagreb, 2004.
91. Petrov, T.: *Modeli analize omeđivanja podataka s primjenom u trgovini*, magistarski rad, Ekonomski fakultet Zagreb, Zagreb, 2002 .
92. Petrović, M.: *Globalizacija i gradovi*, Filozofski fakultet Beograd, 20 – 44, 2004.
93. Petz, B.: *Osnovne statističke metode za nematematičare*, Naklada Slap, Jastrebarsko, 2004.
94. Polet, R.: *Exchange of Best Pracitices: The CAF Experience*, EIPASCOPE, 25th Anniversary Special Issue, 2006.
95. Pravdić, P.: *BSC u profitnim i neprofitnim organizacijama*, 38. Nacionalna konferencija o kaliteti, Kragujevac, 2011.
96. Rabar, D.: *Ocjenjivanje efikasnosti poslovanja hrvatskih bolnica metodom analize omeđivanja podataka*, Ekonomski pregled, Zagreb, 61(9-10), 511-533, 2010.
97. Rabar, D., Blažeković, S.: *Ocjenjivanje efikasnosti hrvatskih županija u turizmu primjenom analize omeđivanja podataka*, Privredna kretanja i ekonomska politika, 127, 25-55, 2011.
98. Raguz, V.I.: *Specifičnosti metodoloških pristupa mjerenju uspješnosti poslovanja kvalitativnim pokazateljima*, Poslovna izvrsnost, Zagreb, 2, 107 – 117, 2010.
99. Ranjit, B.: *Competitive intelligence process and tools for intelligence analysis*, Industrial Management & Data Systems, 108, 510 – 528, 2008.

100. Savić, G., Martić, M.: *Merenje efikasnosti poslovnih sistema, osnovni modeli i procedura primene DEA*, Ekonomska misao, Beograd, 2009.
101. Saraiva, P.H., da Ros, M.J.P., d'Orey, I.,L.: *An EFQM model self-assessment project Covering 50 Portuguese schools*, Proceedings of the 6th World Congress for TQM, 164 - 171, 2001.
102. Schwartz, J.: *The balanced scorecard versus total quality management: Which is better for your organization?*, Military medicine, 170, 855-858, 2005.
103. Scott, A.J., Soja, E., Storper: *Global City Regions: Opening Arguments*, u A., Scoot (Eed.) Global City – Regions, Oxford University Press, Oxford, 2002.
104. Sharp, J.: Microsoft Visual C# 2008 korak po korak", CET, 559-644, 2009.
105. Sikavica, P., Bahtijarević, Š.,F.: Leksikon menadžmenta, Masmedia, Zagreb, 2001.
106. Slijepčević, S.: *Mjerenje efikasnosti javne potrošnje u Hrvatskoj*, doktorska disertacija, Ekonomski fakultet Zagreb, Zagreb, 2009.
107. Staes, P., Thijs, N.: *Quality Management on the European Agenda*, EIPASCOPE, 1, 33-41, 2005., a
108. Staes, P., Thijs, N.: *Report on the State of Affairs on the Common Assessment Framework (CAF) after five years*, EIPASCOPE, 3, 41-49, 2005., b
109. Stevens, M., McGowan R.: *Patterns and Predictors of Economic Development Power in Local Government: A Policy Perspective on Issues in one State*, Policy Studies Review, 6 (3), 554 – 568, 1987.
110. Šegota, A.: *Evaluating shops efficiency using data envelopment analysis: Categorical approach*, Zbornik radova Ekonomskog fakulteta u Rijeci, Rijeka, 195 - 212, 2008.
111. Šegota, A.: *Usporedna analiza efikasnosti prodajnih objekata u maloprodaji*, doktorska disertacija, Ekonomski fakultet Zagreb, Zagreb, 2003.
112. Škuflić, L., Rabar, D., Šokčević, S.: *Assessment of the Efficiency of Croatian Counties Using Dana Envelopment Analysis*, Ekonomska istraživanja, Zagreb, 23(2), 88-101, 2010.
113. Šporčić, M., Martinić, I., Landekić, M., Lovrić, M.: *Analiza omeđivanja podataka kao metoda efikasnosti-mogućnosti primjene u šumarstvu*, Nova mehanizacija šumarstva, Zagreb, 29, 51-59, 2008.
114. Šporčić, M.: *Ocjena uspješnosti poslovanja organizacijskih cjelina u šumarstvu neparametarskim modelom*, doktorska disertacija, Šumarski fakultet Zagreb, Zagreb, 2007.
115. Šporčoć, M., Landekić, M., Lovrić, M., Bogdan, S., Šegotić, K.: *Višekriterijsko odlučivanje kao podrška u gospodarenju šumama – modeli i iskustva*, Šumarski list, 5-6, 275 – 286, 2010.

116. Tica, J.: *Gdje nastaju gradovi*, Ekonomski fakultet u Zagrebu, 2004.
117. Umashev, C., Willett, R.: *Challenges to Implementing Strategic Performance Measurement Systems in Multi-Objective Organizations: The Case of a Large Local Government Authority*, Abacus-a Journal of Accounting Finance and Business Studies, 44, 377-398, 2008.
118. Vincova, K.: *Using DEA Models to Measure Efficiency,* BIATEC, 13(8), 24-28, 2005.
119. Vujović, S.: *Lokalni, glokalni, preduzetnički i socioekološki aspekti savremenog grada*, Beograd, Sociologija, 105 - 122, 2012.
120. Wisniewski, M., S. Olafsson: *Developing balanced scorecard in local authorities: a comparison of experience*, International Journal of Productivity and Performance Management, 53, 602-610, 2004.
121. Woodbury, K., Dollery B., Rao P.: *Is Local Government Efficiency Measurement In Australia Adequate? An Analysis Of The Evidence*, Public Perfomance&Management Review, 77-91, 2003.
122. Worthington, A., Dollery B.: *Incorporating Contextual Information in Public Sector Efficiency Analyses: A Comparative Study of NSW Local Government,* Applied Economics, 34(4), 453-464, 2002.
123. Worthington, A., Dollery, B.: *Measuring Efficiency in Local Government's Planning and Regulatory Function*, Public Productivity and Management Review, 23(4), 468-485, 2000.
124. Worthington, A.: *Cost Efficiency in Australian Local Government: a Comparative Analysis of Mathematical Programming and Econometric Approaches*, Financial Accountability and Management, 16(3), 201-224, 2000.
125. Zhang, J.: *Urbanization, Population Transition and growth*, Oxford Economic Papers, 54, 91-117, 2002.
126. Zhu, J.: *Multidimensional quality-of-life measure with an application to Fortune's best cities,* Socio-Economic Planning Sciences, 35, 263-284, 2001.

OSTALI IZVORI

*** Godišnji obračun Proračuna Grada Samobora za 2005. godinu, Službene vijesti Grada Samobora 3/2006.

*** Godišnji obračun Proračuna Grada Samobora za 2006. godinu, Službene vijesti Grada Samobora 3/2007.

*** Godišnji obračun Proračuna Grada Samobora za 2007. godinu, Službene vijesti Grada Samobora 2/2008.

*** Godišnji obračun Proračuna Grada Siska za 2006. godinu, Službeni glasnik Sisačko-moslavačke županije 7/2007.

*** Godišnji obračun Proračuna Grada Siska za 2007. godinu, Službeni glasnik Sisačko-moslavačke županije broj 7/2007.

*** Godišnji obračun Proračuna Grada Siska za 2008. godinu, Službeni glasnik Sisačko-moslavačke županije broj 6/2009.

*** Godišnji obračun Proračuna Grada Slavonskog Broda za 2005. godinu, Službeni vjesnik Brodsko-posavske županije broj 6/2006.

*** Godišnji obračun Proračuna Grada Slavonskog Broda za 2008. godinu, Službeni vjesnik Brodsko-posavske županije broj 7/2008.

*** Zakonom o općem upravnom postupku, Narodne novine broj 47/2009

*** Europska povelja o lokalnoj samoupravi http://conventions.coe.int/Treaty/EN/Treaties/PDF/Croatian/122-Croatian.pdf (učitano 10. 01. 2011.)

*** Global Competitiveness Report, Growth Competitiveness Index rankings, 2005 and 2004 comparisons,

*** Godišnji obračun proračuna Grada Bjelovara za 2004. godinu, Službeni glasnik Grada Bjelovara, broj 3, 2005.

*** Godišnji obračun proračuna Grada Bjelovara za 2005. godinu, Službeni glasnik Grada Bjelovara, broj 5, 2006.

*** Godišnji obračun proračuna Grada Bjelovara za 2006. godinu, Službeni glasnik Grada Bjelovara, broj 3, 2007.

*** Godišnji obračun proračuna Grada Bjelovara za 2007. godinu, Službeni glasnik Grada Bjelovara, broj 3, 2008.

*** Godišnji obračun Proračuna Grada Bjelovara za 2008. godinu, Službeni vjesnik Grada Bjelovara broj 5/2009.

*** Godišnji obračun proračuna Grada Dubrovnika za 2003. godinu, Službeni glasnik Grada Dubrovnika, broj 3, 2004.
*** Godišnji obračun proračuna Grada Dubrovnika za 2004. godinu, Službeni glasnik Grada Dubrovnika, broj 5, 2005.
*** Godišnji obračun proračuna Grada Dubrovnika za 2005. godinu, Službeni glasnik Grada Dubrovnika, broj 4, 2006.
*** Godišnji obračun proračuna Grada Dubrovnika za 2006. godinu, Službeni glasnik Grada Dubrovnika, broj 4, 2007.
*** Godišnji obračun proračuna Grada Dubrovnika za 2007. godinu, Službeni glasnik Grada Dubrovnika, broj 4, 2008.
*** Godišnji obračun Proračuna Grada Dubrovnika za 2008. godinu, Službeni glasnik Grada Dubrovnika broj 7/2009.
*** Godišnji obračun Proračuna Grada Karlovca za 2005. godinu, Glasnik Grada Karlovca broj 3/2006.
*** Godišnji obračun Proračuna Grada Karlovca za 2007. godinu, Glasnik grada Karlovca, broj 2/2008.
*** Godišnji obračun Proračuna Grada Osijeka za 2005. godinu, Službeni glasnik Grada Osijeka br. 3/2006.
*** Godišnji obračun Proračuna Grada Osijeka za 2006. godinu, Službeni glasnik Grada Osijeka br. 3/2007.
*** Godišnji obračun Proračuna Grada Osijeka za 2007. godinu, Službeni glasnik Grada Osijeka br. 7/2008.
*** Godišnji obračun Proračuna Grada Osijeka za 2008. godinu, Službeni glasnik Grada Osijeka br. 9/2009.
*** Godišnji obračun proračuna Grada Pule za 2003. godinu, Službene novine Grada Pule, broj 4, 2004.
*** Godišnji obračun proračuna Grada Pule za 2004. godinu, Službene novine Grada Pule, broj 7a, 2005.
*** Godišnji obračun proračuna Grada Pule za 2005. godinu, Službene novine Grada Pule, broj 3, 2006.
*** Godišnji obračun proračuna Grada Pule za 2006. godinu, Službene novine Grada Pule, broj 5, 2007.
*** Godišnji obračun proračuna Grada Pule za 2007. godinu, Službene novine Grada Pule, broj 3, 2008.

*** Godišnji obračun Proračuna Grada Pule za 2008. godinu, Službene novine Grada Pule broj 11/2009.
*** Godišnji obračun proračuna Grada Rijeke za 2003. godinu, Službene novine - glasilo Primorsko goranske županije, broj 12/2004.
*** Godišnji obračun proračuna Grada Rijeke za 2004. godinu, Službene novine -glasilo Primorsko goranske županije, broj 8/2005.
*** Godišnji obračun proračuna Grada Rijeke za 2005. godinu, Službene novine -glasilo Primorsko goranske županije, broj 9/2006.
*** Godišnji obračun proračuna Grada Rijeke za 2006. godinu, Službene novine -glasilo Primorsko goranske županije, broj 8/2007.
*** Godišnji obračun proračuna Grada Rijeke za 2007. godinu, Službene novine -glasilo Primorsko goranske županije, broj 6/2008.
*** Godišnji obračun Proračuna Grada Rijeke za 2008. godinu, Službene novine Primorsko-goranske županije, broj13/2009.
*** Godišnji obračun proračuna Grada Samobora za 2003. godinu, Službene vijesti Grada Samobora, broj 3, 2004.
*** Godišnji obračun proračuna Grada Samobora za 2004. godinu, Službene vijesti Grada Samobora, broj 3, 2005.
*** Godišnji obračun proračuna Grada Samobora za 2005. godinu, Službeni vijesti Grada Samobora, broj 3, 2006.
*** Godišnji obračun proračuna Grada Samobora za 2006. godinu, Službeni vijesti Grada Samobora, broj 3, 2007.
*** Godišnji obračun proračuna Grada Samobora za 2007. godinu, Službene vijesti Grada Samobora, broj 2, 2008.
*** Godišnji obračun Proračuna Grada Siska za 2005. godinu, Službeni glasnik Sisačko-moslavačke županije, broj 12/2006.
*** Godišnji obračun proračuna Grada Slavonskog Broda za 2003. godinu, Službeni vjesnik Brodsko – posavske županije, broj 9/2004.
*** Godišnji obračun proračuna Grada Slavonskog Broda za 2004. godinu, Službeni vjesnik Brodsko – posavske županije, broj 14/2005.
*** Godišnji obračun proračuna Grada Slavonskog Broda za 2005. godinu, Službeni vjesnik Brodsko – posavske županije, broj 6/2006.
*** Godišnji obračun proračuna Grada Slavonskog Broda za 2007. godinu, Službeni vjesnik Brodsko – posavske županije, broj 5/2008.

*** Godišnji obračun Proračuna Grada Splita za 2004. godinu, Službeni glasnik Grada Splita, broj 17/2005.
*** Godišnji obračun Proračuna Grada Splita za 2005. godinu, Službeni glasnik Grada Splita broj 12/2006.
*** Godišnji obračun Proračuna Grada Splita za 2006. godinu, Službeni glasnik Grada Splita, broj 12/2007.
*** Godišnji obračun Proračuna Grada Splita za 2007. godinu, Službeni glasnik Grada Splita broj 13/2008.
*** Godišnji obračun Proračuna Grada Splita za 2008. godinu, Službeni glasnik Grada Splita broj 19/2009.
*** Godišnji obračun proračuna Grada Šibenika za 2003. godinu, Službeni vjesnik Šibensko-kninske županije, 7, 2004.
*** Godišnji obračun proračuna Grada Šibenika za 2004. godinu, Službeni vjesnik Šibensko-kninske županije, broj 8/2005.
*** Godišnji obračun proračuna Grada Šibenika za 2005. godinu, Službeni vjesnik Šibensko-kninske županije, broj 8/2006.
*** Godišnji obračun proračuna Grada Šibenika za 2006. godinu, Službeni vjesnik Šibensko-kninske županije,broj 26/2007.
*** Godišnji obračun proračuna Grada Šibenika za 2007. godinu, Službeni glasnik Grada Šibenika, broj 4/2008.
*** Godišnji obračun proračuna Grada Varaždina za 2003. godinu, Službeni vjesnik Grada Varaždina, broj 4/2004.
*** Godišnji obračun proračuna Grada Varaždina za 2004. godinu, Službeni vjesnik Grada Varaždina, broj 3, 2005.
*** Godišnji obračun proračuna Grada Varaždina za 2005. godinu, Službeni vjesnik Grada Varaždina, broj 4/2006.
*** Godišnji obračun proračuna Grada Varaždina za 2006. godinu, Službeni vjesnik Grada Varaždina, broj 6/2007.
*** Godišnji obračun proračuna Grada Varaždina za 2007. godinu, Službeni vjesnik Grada Varaždina, broj 4/2008.
*** Godišnji obračun Proračuna Grada Varaždina za 2008. godinu, Službeni vjesnik Grada Varaždina 2/2008.
*** Godišnji obračun Proračuna Grada Velike Gorice za 2005. godinu, Službeni vjesnik Grada Velike Gorice, broj 11/2006.

*** Godišnji obračun proračuna Grada Velike Gorice za 2006. godinu, Službeni glasnik Grada Velike Gorice, broj 11/2007.
*** Godišnji obračun proračuna Grada Velike Gorice za 2007. godinu, Službeni glasnik Grada Velike Gorice, broj 6/2008.
*** Godišnji obračun Proračuna Grada Velike Gorice za 2008. godinu, Službeni vjesnik Grada Velike Gorice, broj 10/2009.
*** Godišnji obračun proračuna Grada Zadra za 2003. godinu, Glasnik Grada Zadra, broj 2/2004.
*** Godišnji obračun proračuna Grada Zadra za 2004. godinu, Glasnik Grada Zadra, broj 2/2005.
*** Godišnji obračun proračuna Grada Zadra za 2005. godinu, Glasnik Grada Zadra, broj 2/2006.
*** Godišnji obračun proračuna Grada Zadra za 2006. godinu, Glasnik Grada Zadra, broj 2/2007.
*** Godišnji obračun proračuna Grada Zadra za 2007. godinu, Glasnik Grada Zadra, broj 8/2008.
*** Godišnji obračun Proračuna Grada Zadra za 2008. godinu, Glasnik Grada Zadra broj 9/2009.
*** Odluka o donošenju godišnjeg obračuna Proračuna Grada Karlovca za 2005. godinu, Glasnik grada Karlovca, broj 3/2006.
*** Odluka o godišnjem obračunu Proračuna Grada Karlovca za 2006. godinu, Glasnik grada Karlovca, broj 7/2007.
*** Odluka o usvajanju godišnjeg obračuna Proračuna Grada Karlovca za 2003. godinu, Glasnik grada Karlovca, broj 4/2004.
*** Odluka o utvrđenju godišnjeg obračuna Proračuna Grada Karlovca za 2004. godinu, Glasnik grada Karlovca, broj 7/2005.
*** Odluka povodom razmatranja Godišnjeg obračuna Proračuna Grada Osijeka za 2003. godinu, Službeni glasnik Grada Osijeka, broj 2/2004.
*** Odluka povodom razmatranja Godišnjeg obračuna Proračuna Grada Osijeka za 2004. godinu, Službeni glasnik Grada Osijeka, broj 2/2005.
*** Odluka povodom razmatranja Godišnjeg obračuna Proračuna Grada Osijeka za 2005. godinu, Službeni glasnik Grada Osijeka, broj 3/2006.
*** Odluka povodom razmatranja Godišnjeg obračuna Proračuna Grada Osijeka za 2006. godinu, Službeni glasnik Grada Osijeka, broj 3/2007.

*** Odluka povodom razmatranja Godišnjeg obračuna Proračuna Grada Osijeka za 2007. godinu, Službeni glasnik Grada Osijeka, broj 7/2008.
*** Popis stanovništva 2001., Državni zavod za statistiku [URL:http://www.dzs.hr/Hrv/censuses/Census2001/Popis/H01,html], 10.05.2008.
*** Pravilnik o obliku, sadržaju, roku i načinu dostave poslovnih knjiga, evidencija i izvješća koji se čuvaju u elektroničkom obliku, Narodne novine broj 59/2009.
*** Pravilnik o obliku, sadržaju, roku i načinu dostave poslovnih knjiga, evidencija i izvješća koji se čuvaju u elektroničkom obliku, Narodne novine broj 59/2009
*** Pred-pristupni ekonomski program 2005-2007,Vlada RH, Zagreb, 2004.
*** Urban Population Develppment and the Enviromental 2007, UN, 2008; [URL:http://www.un.org/esa/population/publications/2007_PopDevt/Urban_2007.pdf], 11.11.2008.
*** Usklađenost hrvatskoga zakonodavnog okvira s Europskom poveljom o lokalnoj samoupravi, The Urban institute, Zagreb, 2005.
*** Zakon o državnoj informacijskoj infrastrukturi, Narodne novine broj 82/2014
*** Zakon o financiranju jedinica lokalne samouprave i uprave *(pročišćeni tekst),* Sabor Republike Hrvatske, Narodne novine broj 150, 2002.
*** Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, Narodne novine broj 33/01, 60/01 - vjerodostojno tumačenje i 129/05
*** Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, Sabor Republike Hrvatske, Narodne novine broj 22, 2001.
*** Zakon o računovodstvu, Sabor Republike Hrvatske, Narodno novine broj 90, 1992.
*** Zakon o trgovačkim društvima, Sabor Republike Hrvatske, Narodne novine broj 111/93 i 34/99, 1999.
*** Zakonom o sustavu državne uprave, narodne novine broj 150/2011
*** Zakonu o fiskalnoj odgovornosti, Narodne novine broj 139/2012 i 19/2014
*** Zakonu o Proračunu, Narodne novine broj 87/2008 i 136/2012

ŽIVOTOPIS

Tomislav Bogović rođen je 13. studenog 1966. godine u Varaždinu gdje je završio srednju školu u Centru za školovanje NGRM kadrova 1986. godine. Diplomirao je Agronomskom fakultetu u Zagrebu 1991. godine na smjeru za ratarstvo.

Poslijediplomski studij „Menadžment poslovnih sustava“ završio je 2006. godine na Fakultetu organizacije i informatike u Varaždinu i stekao znanstveni stupanj magistra društvenih znanosti, polje informacijskih znanosti.

Nakon završetka diplomskog studija radio je kao agronom u trgovini Nova Gea u Nedelišću, a od 1995. godine radio je u Gospodarskoj školi Čakovec kao profesor-predavač stručnih predmeta s područja poljoprivrede. Od 2000. do 2005. godine profesionalno je obnašao funkciju zamjenika gradonačelnika Grada Varaždina, a od tada radi na poslovima savjetnika za gospodarstvo u Gradu Varaždinu.

Na Ekonomskom fakultetu u Zagrebu 2006. godine završio je program Korporativno upravljanje za članove nadzornih odbora i upravnih vijeća, a 2007. godine izobrazbu za Učinkovito upravljanje u lokalnoj i regionalnoj samoupravi kao i niz stručnih usavršavanja na području menadžmenta javne uprave.

Od važnijih projekta u Gradu Varaždinu ističe se kao voditelj projekta razvoja Zone malog poduzetništva u Jalkovcu i urednik web stranica Grada Varaždina.

Oženjen je i otac četvero djece, a u slobodno vrijeme bavi se vatrogastvom, poljoprivredom i sportom.

Popis znanstvenih radova:

1. Bogović, T., Cingula M.**:** *Higher education impact on informatics entrepreneurship in Varazdin county,* Međunarodna znanstvena konferencija: Focus on Regional Development, DAAAM &Vallis Aurea, Požega, 2008.
2. Bogović, T.: *Gospodarski razvoj Grada Varaždina u recentnoj povijesti Republike Hrvatske***,** HAZU, Međunarodni znanstveni skup u povodu 800 godina slobodnog kraljevskog grada Varaždina**,** Varaždin, 2009.