Ocjena učinkovitosti upravljanja nekretninama u vlasništvu gradova u Republici Hrvatskoj

Ignjatović, Marko

Doctoral thesis / Disertacija

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Economics and Business / Sveučilište u Zagrebu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:148:021686

Rights / Prava: Attribution-NonCommercial-ShareAlike 3.0 Unported / Imenovanje-Nekomercijalno-Dijeli pod istim uvjetima 3.0

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

Repository / Repozitorij:

REPEFZG - Digital Repository - Faculty of Economcs & Business Zagreb

Sveučilište u Zagrebu

EKONOMSKI FAKULTET

Marko Ignjatović

OCJENA UČINKOVITOSTI UPRAVLJANJA NEKRETNINAMA U VLASNIŠTVU GRADOVA U REPUBLICI HRVATSKOJ

DOKTORSKI RAD

Zagreb, 2020.

Sveučilište u Zagrebu

EKONOMSKI FAKULTET

Marko Ignjatović

OCJENA UČINKOVITOSTI UPRAVLJANJA NEKRETNINAMA U VLASNIŠTVU GRADOVA U REPUBLICI HRVATSKOJ

DOKTORSKI RAD

Mentor: doc. dr. sc. Marko Primorac

Zagreb, 2020.

University of Zagreb

FACULTY OF ECONOMICS AND BUSINESS

Marko Ignjatović

ASSESSMENT OF THE EFFECTIVENESS OF CITY OWNED REAL ESTATE MANAGEMENT IN THE REPUBLIC OF CROATIA

DOCTORAL THESIS

Supervisor: Doc. Marko Primorac, PhD

Zagreb, 2020.

IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je doktorski rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija.

Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Marko Ignjatović

U Zagrebu, 27. svibnja 2020. godine

PODACI I INFORMACIJE O DOKTORANDU

Ime i prezime: **Marko Ignjatović**

Datum i mjesto rođenja: **20. 8. 1983., Zagreb**

Naziv završenog fakulteta i godina diplomiranja: **Ekonomski fakultet Zagreb, 2009.**

Naziv specijalističkog studija, fakultet i godina magistriranja: **Specijalistički stručni studij, MBA program, Financije i računovodstvo, Zagrebačka škola ekonomije i managementa, Zagreb, 2012.**

PODACI O DOKTORSKOM RADU

Naslov doktorskog rada:

Ocjena učinkovitosti upravljanja nekretninama u vlasništvu gradova u Republici Hrvatskoj

Fakultet na kojem je disertacija obranjena: **Ekonomski fakultet Zagreb**

POVJERENSTVA, OCJENA I OBRANA RADA

Datum prihvaćanja teme: **28. svibnja 2019. godine**

Mentor: **doc. dr. sc. Marko Primorac**, Ekonomski fakultet Zagreb

Povjerenstvo za ocjenu rada:

1. **prof. dr. sc. Hrvoje Šimović**, Ekonomski fakultet Zagreb, predsjednik
2. **doc. dr. sc. Marko Primorac**, Ekonomski fakultet Zagreb, član i mentor
3. **prof. dr. sc. Davor Vašićek**, Ekonomski fakultet Rijeka, član

Povjerenstvo za obranu rada:

1. **prof. dr. sc. Hrvoje Šimović**, Ekonomski fakultet Zagreb, predsjednik
2. **doc. dr. sc. Marko Primorac**, Ekonomski fakultet Zagreb, član i mentor
3. **prof. dr. sc. Davor Vašićek**, Ekonomski fakultet Rijeka, član

Datum obrane rada: **15. svibnja 2020. godine**

Ovaj rad posvećujem svojim roditeljima kao zahvalu na povjerenju i podršci tokom mog studiranja. Zahvaljujem svojoj djevojci i obitelji na razumijevanju tokom same izrade i obrane. Posebno mjesto zauzima prof. dr sc. Anto Bajo, moj prvi mentor, kolega i profesor koji me uveo u znanstveno područje rada. Veliko hvala mom drugom mentoru doc.dr.sc. Marku Primorscu na podršci pruženoj u izazovnim trenucima na samom kraju procesa pripreme i obrane rada. Također posebno zahvaljujem članovima vijeća, prof.dr.sc. Hrvoje Šimović i prof. dr. sc. Davor Vašiček, na vremenu izdvojenom za čitanje rada i konstruktivnim prijedlozima.

SAŽETAK

Predmet istraživanja doktorske disertacije su nekretnine u vlasništvu gradova u Republici Hrvatskoj, ocjena i prepoznavanje glavnih odrednica učinkovitog upravljanja nekretninama. Glavno istraživačko pitanje na koje doktorska disertacija treba odgovoriti je upravljaju li gradovi učinkovito nekretninama u svom vlasništvu. Upravljanje gradskom imovinom možemo definirati kao sintagmu koja objedinjuje niz različitih složenih i multidisciplinarnih aktivnosti u okviru poslovanja gradova. Procesom decentralizacija, lokalne samouprave su gotovo „preko noći" postali novi nositelji vlasništva velikog broja nekretnina. Tako i gradovi u vlasništvu imaju veliki broj i vrijednost imovine, a među kojom nekretnine predstavljaju najvrjedniju imovinu. Istraživanje predstavlja prvu empirijsku analizu učinkovitosti upravljanja nekretninama u vlasništvu gradova u Republici Hrvatskoj, pri čemu znanstveni problem rada proizlazi iz nepostojanja sustavne brige o nekretninama, a posebice nepostojanja primjerenog mjerila (*benchmarka*) za mjerenje uspješnosti. Uvažavajući navedeno, može se zaključiti da i površan pregled problematike upravljanja nekretninama ukazuje da je riječ o izrazito složenom ali dinamičnom području koje traži angažman stručnjaka različitih profila i znanstveni pristup.

Doktorski rad nastoji dati odgovore na ključna istraživačka pitanja odnosno nastoji utvrditi koja obilježja gradova utječu na učinkovitost upravljanja nekretnina, utječe li veličina, geografski položaj na učinkovitost upravljanja. Također, neki od znanstvenih ciljeva istraživanja imaju zadatak empirijskom analizom istražiti koliko učinkovito gradovi upravljanju i koja obilježja utječu. Sukladno navedenim istraživačkim pitanjima i ciljevima, testirat će se pet hipoteza. Postavljene hipoteze testirat će se korištenjem sekundarnih podataka, a kvalitativna analiza temelji se na dva analitička pristupa, neparametraskoj metodi omeđivanja podataka i Tobit panel regresiji. Upravljanje nekretninama je osjetljivo pitanje od prvorazrednog političkog značaja sa značajnim i dalekosežnim posljedicama po širu društvenu zajednicu. Gradovi upravljanje nekretninama vide kao moćan alat za stvaranje dodane vrijednosti, smanjenje troškova održavanja i upravljanja te poboljšanja kvalitete života u zajednici. Nekretnine u vlasništvu gradova i njihova velika vrijednost posredno su vlasništvo svih građana, zbog čega je bitno osigurati njihovo učinkovito upravljanje.

Ključne riječi: učinkovitost, upravljanje nekretninama, gradovi, analiza omeđivanja podataka

SUMMARY

Research subject of this doctoral thesis are real estates owned by cities in the Republic of Croatia, management effectiveness assessment of the mentioned real estates and analysis of efficiency determinants. Main research question to which this thesis should provide an answer is whether the cities manage real estates in their ownership in an effective manner. Management of city property can be defined as a phrase which encompasses a range of different complex and multidisciplinary activities within cities' business operations. Decentralisation process has almost overnight turned local self-governments to "real estate giants", i.e. new owners of real estates, where cities now have properties of a significant number and great value in their ownership, amongst which the real estates are the most valuable ones. Research represents the first empirical management efficiency analysis of real estates owned by the cities in the Republic of Croatia, whereby the scientific problem of the paper results from the lack of systematic care of real estates. Observing the financial aspect, there is also the problem of the non-existence of an appropriate benchmark which would be appropriate for the measurement of successfulness. While considering the abovementioned, it can be concluded that even a superficial overview of the issue of real estate management is sufficient to conclude that it is an extremely complex and dynamic area which requires significant engagement of experts of different profiles and a scientific approach.

Some of the research questions to which the doctoral thesis provides answers are: which features of the cities influence the effectiveness of real estate management, do the size and geographical position influence the management effectiveness. Also, some of the scientific goals of the research have the function of empirical analysis research of cities' management efficiency, as well as the features on which they effect. In accordance with the mentioned research questions and goals, five hypotheses will be tested. The set hypotheses will be tested with the use of secondary data, quantitative analysis is based on two analytic approaches, nonparametric method of data hedging and Tobit panel regression. Real estate management is a sensitive question of primary political significance with significant and far-reaching consequences on the wider social community. Cities consider real estate management as a powerful tool for creating added value, lowering of maintenance and management costs and improvement of quality of life in the community. Real estates owned by cities and their great value are indirect ownership of all citizens, what makes the insurance of their effective management important.

Keywords: efficiency, real estate management, cities, data hedging analysis

SADRŽAJ

SAŽETAK iv
SUMMARY v
SADRŽAJ vi
1. UVOD 1
1.1. Područje i tema doktorskog rada 1
1.2. Predmet i problem istraživanja doktorskog rada 1
1.3. Ciljevi doktorskog rada 9
1.4. Hipoteze istraživanja 10
1.5. Izvori podataka i metode istraživanja 16
1.6. Očekivani znanstveni doprinos doktorskog rada 20
1.7. Struktura doktorskog rada 22
2. TEMELJNE ZNAČAJKE I MODELI UPRAVLJANJA NEKRETNINAMA U VLASNIŠTVU GRADOVA 24
2.1. Uloga i značaj nekretnina u vlasništvu gradova 24
2.1.1. Osnovna obilježja nekretnina u vlasništvu gradova 24
2.1.2. Vrste nekretnina 27
2.1.3. Uloga upravljanja nekretninama u upravljanju gradovima 29
2.2. Modeli i prakse upravljanja nekretninama gradova 32
2.2.1. Pregled inozemnih primjera upravljanja nekretninama gradova 32
2.2.2. Model logističke podrške upravljanju nekretninama gradova 47
2.2.3. Modeli upravljanja nekretninama u javnom sektoru 50
2.3. Pretpostavka za upravljanje nekretninama gradova 52
2.3.1. Procjene vrijednosti nekretnina 53
2.3.2. Upravljanje imovinom gradova iz bilančne perspektive 58
2.4. Učinkovitost upravljanja gradovima i važnost upravljanja nekretninama za uspješnost gradova 60
2.4.1. Politike lokalnog ekonomskog razvoja i razvojni potencijali gradova 60
2.4.2. Značaj strateškog upravljanja nekretninama za gospodarski razvoj gradova 61
2.5. Utjecaj upravljanja nekretninama na lokalni ekonomski razvoj i na uspješnost financijskog poslovanja gradova 64
3. UPRAVLJANJE NEKRETNINAMA U VLASNIŠTVU GRADOVA U REPUBLICI HRVATSKOJ 67
3.1. Institucionalni okvir upravljanja nekretninama u Republici Hrvatskoj 67

3.2. Vrijednosti i struktura nekretnina u vlasništvu gradova 71
3.3. Praksa i modeli upravljanja imovinom u gradovima kroz Projekt reforme lokalne samouprave (PRLS Model) 78
3.4. Utjecaj upravljanja nekretninama na gospodarski razvoj i na financijski položaj gradova 97
3.5. Revizija učinkovitosti – upravljanje i raspolaganje nekretninama lokalne i područne samouprave 101
4. PREGLED EMPIRIJSKIH ISTRAŽIVANJA O UČINKOVITOSTI UPRAVLJANJA NEKRETNINAMA 107
4.1. Važnost mjerenja učinkovitosti u javnom sektoru 107
4.2. Pregled dosadašnjih istraživanja i metoda za ocjenu učinkovitosti 115
4.2.1. Razvoj metodologije za mjerenje učinkovitosti 122
4.2.2. Parametarske metode 126
4.2.3. Neparametarske metode 130
4.2.4. Mjerenje ostvarenih rezultata (pokazatelji učinkovitosti) 137
4.3. Rasprava i analiza prednosti i nedostataka alternativnih metoda mjerenja učinkovitosti 141
5. EMPIRIJSKI MODEL ZA OCJENU UČINKOVITOSTI UPRAVLJANJA NEKRETNINAMA U HRVATSKIM GRADOVIMA 146
5.1. Odabir varijabli i izvori podataka 147
5.1.1. Varijable koje se koriste za izračun zavisne varijable 148
5.1.2. Glavne objašnjavajuće varijable 151
5.1.3. Skupina kontrolnih varijabli 153
5.1.4. Popis varijabli korištenih u analizi 157
5.2. Definiranje modela za ocjenu učinkovitosti upravljanja nekretninama 159
5.2.1. Metoda analize omeđivanja podataka 159
5.2.2. Definiranje ulaza i izlaza za metodu omeđivanja podataka 162
5.2.3. Definiranje modela analize omeđivanja podataka 166
5.2.4. Definiranje Tobit panel modela 168
5.3. Rezultati empirijskog istraživanja 170
5.3.1. Učinkovitost upravljanja nekretninama u hrvatskim gradovima 170
5.3.2. Učinkovitost upravljanja nekretninama u velikim gradovima u usporedbi s ostalim gradovima 175
5.3.3. Učinkovitost upravljanja nekretninama s obzirom na geografski položaj gradova 177

5.3.4. Učinkovitost upravljanja nekretninama u gradovima županijskim središtima u usporedbi s ostalim gradovima ... 184
5.3.5. Utjecaj primjene modela projekta Reforme lokalne samouprave na učinkovitosti upravljanja nekretninama u hrvatskim gradovima ... 187
5.4. Ograničenja istraživanja i preporuke za buduća istraživanja ... 189
6. ZAKLJUČAK ... 190
POPIS LITERATURE ... 197
POPIS GRAFIKONA ... 209
POPIS SLIKA ... 210
POPIS TABLICA ... 211
PRILOZI ... 213
Prilog 1 Naziv grada i temeljne informacije i transparentnost ... 213
Prilog 2 Broj stanovnika u gradovima ... 218
Prilog 3 Fiskalni kapacitet gradova ... 223
Prilog 4 Broj poduzetnika u gradovima ... 228
Prilog 5 Stopa nezaposlenost u gradovima ... 233
Prilog 6 Vrijednost nekretnina po stanovniku u gradovima ... 238
Prilog 7 Prihodi od nekretnina u gradovima ... 243
Prilog 8 Vrijednost nekretnina gradova ... 252
Prilog 9 Tablica varijabli korištenih u analizi ... 261
POJMOVNIK ... 264
ŽIVOTOPIS ... 267

1. UVOD

1.1. Područje i tema doktorskog rada

Prema postojećoj klasifikaciji i pravilnicima, konkretno ovaj doktorski rad pozicionira u područje društvenih znanosti, znanstvenog polja ekonomije, znanstvene grane javne financije. Područje istraživanja doktorskog rada jest upravljanje nekretninama u vlasništvu gradova u Republici Hrvatskoj.

Upravljanje nekretninama predstavlja proces donošenja i provođenja odluka koje predstavljaju nabavu, korištenje i raspolaganje nekretnina u vlasništvu grada. Navedene aktivnosti trebaju kroz cijeli period korištenja nekretnina donositi nove vrijednosti uz kontinuiran rast prihoda, kontrolirani nadzor troškova, upravljanje rizicima i održavanjem optimalne razine kvalitete funkcioniranja predmetne imovine.

Gradovi u vlasništvu ili na raspolaganju imaju značajan broj i veliku vrijednost imovine, a naročito nekretnina. Navedeni pojavni oblik imovine (nekretnine) predstavlja izuzetno veliki potencijal koji prema dosadašnjim analizama nije u potpunosti iskorišten. Navedenu problematiku obrađuje vrlo malo radova, a prvenstveno iz aspekta ocjene učinkovitosti (analize i praćenje) i preporuka (alata) za kvalitetnije upravljanje.

Stoga će upravo takav pristup istraživanju ove tematike predstavljati odmak od postojeće literature. Ovo istraživanje i navedene preporuke zbog svoje specifičnosti imaju za cilj nadograditi postojeću literaturu napisanu na temu ocjene učinkovitosti upravljanja nekretninama u vlasništvu gradova.

1.2. Predmet i problem istraživanja doktorskog rada

Znanstveni problem rada proizlazi iz nepostojanja sustavne brige o nekretninama u vlasništvu gradova u Republici Hrvatskoj, odnosno ocjenjivanja upravljaju li gradovi učinkovito nekretninama te analizi odrednica učinkovitosti, koristeći primjerene znanstvene metode. Kada

je riječ o financijskom aspektu, dodatan je problem nepostojanja primjerenog mjerila (*benchmarka*) koje bi bilo prikladno za mjerenje njihove uspješnosti.

Glavna su problemska pitanja ovog istraživanja upravljaju li gradovi učinkovito nekretninama u svom vlasništvu, odnosno koja obilježja gradova utječu na učinkovitost upravljanja nekretninama te utječe li veličina ili geografski položaj gradova na učinkovitost upravljanja.

Značaj teme predmeta istraživanja doktorskog rada potvrđuje i veći broj dosad objavljenih radova. Dio radova usmjeren je na upravljanje nekretninama na razini središnje države (Kask, 2014), posebice analizama pojedinih segmenata upravljanja (baze podataka, vrednovanje) u područjima pojedinih država (na lokalnoj razini). Istaknutiji radovi na temu upravljanja imovinom prisutni su kod autora: Hanis, Trigunarsyah and Susilawati (2011), Phelps (2010), Kaganova i Undeland (2001). Većina se autora susretala s problemom prikupljanja podataka o količini, vrijednosti i obujmu, što je otežavalo provedbu istraživanja, analizu podataka i donošenje relevantnih zaključaka.

Koncept učinkovitosti upravljanja u ovom je radu definiran kroz prizmu tehničke učinkovitosti, tj. promatra se koliko jedinice promatranja (gradovi) učinkovito pretvaraju inpute (nekretnine u svojem vlasništvu) u output (prihodi od nekretnina u gradskom proračunu). U tom se smislu u ovom radu, korištenjem odgovarajućih analitičkih metoda, kvantificira uspješnost lokalnih jedinica u upravljanju inputima kroz izračun pokazatelja učinkovitosti upravljanja nekretninama u gradovima. Pokazatelj učinkovitosti upravljanja nekretninama omogućava usporedbu učinkovitosti među gradovima te procjenu relativne učinkovitosti u odnosu na najuspješnije gradove te u odnosu na prosjek gradova u pojedinim godinama, ali i cijelom promatranom razdoblju. Na taj se način mogu identificirati gradovi koji prema pokazatelju učinkovitosti prednjače, ali i oni koji značajno zaostaju, tj. koji neučinkovito upravljanju nekretninama u svojem vlasništvu. Identificiranje najboljih i najslabijih slučajeva te analiza različitih ekonomskih te institucionalnih odrednica učinkovitosti omogućava iznošenje zaključaka o najboljim praksama (eng. best practices) te potrebnim alatima za unaprjeđenje okvira upravljanja nekretninama u gradovima.

Istraživači se nisu usuglasili oko podrijetla upravljanja nekretninama. Međutim postoji suglasje da se upravljanje razvilo iz drugih disciplina. Primjerice, Edwards (2009) tvrdi da je koncept upravljanje nekretninama relativno nov i obuhvaća aktivnosti koje su provođene i u prethodnom razdoblju, fragmentirano, a razvile su se tijekom nekoliko desetljeća industrijskog doba.

Tijekom razvojne faze, upravljanje nekretninama prihvaća i implementira druge discipline i tehnike. Bez obzira na podrijetlo upravljanja nekretninama, organizacije javnog i lokalnog sektora počele su cijeniti njegove pozitivne učinke. Gradovi upravljanje nekretninama vide kao moćan alat za stvaranje dodane vrijednosti, smanjenje troškova održavanja i upravljanja te poboljšanja kvalitete života u zajednici.

Promatrajući prakse upravljanje nekretninama u gradovima diljem svijeta uočit će se nekoliko identičnih okolnosti. Procesom decentralizacija lokalne samouprave gotovo su preko noći postali "nekretninski divovi", odnosno novi nositelji vlasništva nekretnina (Hentschel et al., 2007). Međutim, navedenu transformaciju ne prati povećanje prihoda potrebnih za uredno evidentiranja promjena i održavanja navedenih nekretnina (Banner et al., 1995). Postoji veliki raskorak između potražnje za javnim uslugama i dostupnosti nekretnina kao alata koji utječu na uspješnost pružanja javnih usluga (Ayuningtiyas et al., 2008).

Jedinice lokalne samouprave u Republici Hrvatskoj u vlasništvu imaju veliki broj različitih oblika imovine. Nekretnine (zemljišta, poslovni prostori i stanovi) predstavljaju najvrjedniji pojavni oblik u portfelju nefinancijske imovine. Navedene vrste nekretnina (nefinancijska imovina) posredno su vlasništvo svih građana, zbog čega je bitno osigurati njihovo učinkovito upravljanje. Nažalost, nekretnine su slabo korišten izvor financiranja države i jedinica lokalne samouprave, posebice gradova. U radu će se utvrdit način evidentiranja i vrednovanja nekretnina u vlasništvu gradova, te način i metode upravljanja u praksi.

Gradovi pružaju širok raspon usluga (predškolski odgoj, obrazovanje, stanovanje i ostalo) i vlasnici su većeg fonda nekretnina (kvadrata) i zbog te osobine imaju utjecaj na kreiranje strateških politika na svom području (Dent, 2002). U brojnim državama (posebice u razvoju) slabo je razvijen okvir za upravljanje nekretninama pa su zanemarene čak i osnovne pretpostavke za kvalitetno upravljanje poput inventure, informatizacije, te praćenje prihoda i troškova od predmetnih nekretnina (Kaganova, 2000).

Tablica 1-1 Vrijednost nefinancijske imovine lokalnih jed. 2004. - 2016. (u mlrd. kuna)

Razina lokalne vlasti	Županije	Gradovi	Općine	Ukupno
Broj lokalnih jedinica	20	128	428	576
2004.	0.5	2.8	6.9	29.2
2005.	0.5	23.9	7.7	32.1
2006.	0.7	25.8	8.6	35.1
2007.	0.8	29.3	10.6	40.7
2008.	0.9	36.5	12.3	49.7
2009.	1.1	41.7	13.7	56.5
2010.	1.2	44.0	14.5	59.7
2011.	1.2	50.5	15.2	66.9
2012.	1.2	58.7	16.2	76.2
2013.	1.5	63.7	17.2	82.5
2014.	1.7	66.7	17.9	86.3
2015.	1.9	78.2	18.7	98.8
2016.	2.1	77.1	19.7	98.9

Izvor: Državni ured za reviziju, Revizija učinkovitosti upravljanja nekretninama lokalnih jedinica, 2016.

Prema Ustavu Republike Hrvatske jedinica lokalne samouprave (općina i gradova) obavlja poslove djelokruga na lokalnoj razini kojima se kroz zakonom definirane aktivnosti neposredno ostvaruju određene potrebe građana. Glavni zadaci kojim se ostvaruju određene potrebe gađana usmjerene su na izgradnju i održavanje naselja, zatim prostorno i urbanističko planiranje, izgradnja i održavanje komunalne infrastrukture, brigu o djeci predškolskog uzrasta, zatim osnovnoškolsko obrazovanje, sport, kultura kao i sve ostale aktivnosti definirane zakonom. Nefinancijska imovina 127 gradova u 2016. čini 78% vrijednosti ukupne imovine svih jedinica lokalne i područne samouprave. Knjigovodstvena vrijednost nekretnina gradova u 2016. iznosi 81 milijardu kuna. Stoga se gradovi nameću kao dobar uzorak lokalnih jedinica za ocjenu učinkovitosti upravljanja nekretninama.

Tranzicijskim promjenama unazad četvrt stoljeća nastale su značajne promjene u pristupu upravljanja nekretninama, pri čemu je ostvaren spor napredak u ispunjenju temeljnog uvjeta za uspješnije upravljanje nekretninama, a to su potpune i uređene evidencije o vrsti, namjeni, broju, vrijednosti, te generiranim prihodima i rashodima na nekretninama.

Bez uređenih evidencija teško je učinkovito upravljati imovinom (Dent, 2014). Uredne evidencije i javno provođenje postupaka upravljanja i raspolaganja (zakupi, najmovi, zamjene,

prodaje, korištenje s valjanom pravnom osnovom i dr.) pretpostavka je transparentnog upravljanja. To su ujedno preduvjeti temeljem kojih bi građani i poslovna zajednica mogli prepoznati i ocijeniti kvalitetu upravljanja i pružiti/uskratiti podršku lokalnoj vlasti putem izbora i referenduma ili drugim oblicima izjašnjavanja.

Proces upravljanja nekretninama na temeljnoj razini definiran je kao proces koji podatke o nekretninama pretvara u radnju (Thorncroft, 1965). Naravno, gradovi nisu jedine institucije koje mogu odlučivati o učinkovitijem upravljanju i raspolaganju nekretninama lokalne zajednice. Naime, česti slučajevi neuređenih imovinsko-pravnih odnosa (posebice neuređeno stanje u zemljišnim knjigama) glavna su ograničenja učinkovitom upravljanju nekretninama lokalne zajednice. Stoga treba ukazati i na česte probleme evidencije imovine između države i lokalnih jedinica (npr. nekretnine bivših vojarni, objekti Hrvatskih voda, šumska dobra, poslovni prostori u povratu) zbog kojih dolazi do obustavljanja provedbe planiranih kapitalnih projekata.

Korištenje nekretnina u lokalnoj zajednici treba biti usmjereno (Kaganova, 2006):

(1) potrebama lokalne zajednice (komunalna infrastruktura, prometnice itd.) kao i svim zakonima definiranim obvezama (groblja, predškolski odgoj, mjesna samouprava i dr.)

(2) potpori društveno korisnih, sportskih, kulturnih, nevladinih, političkih i drugih sadržaja

(3) ostvarivanju prihoda prema tržišnim uvjetima za sve nekretnine.

Za učinkovito upravljanje nekretninama potrebne su cjelovite i sveobuhvatne evidencije o pojavnim oblicima imovine gradova. U današnje vrijeme takve evidencije nisu moguće bez informacijske potpore.

Ministarstvo državne imovine[1] naslijedilo je Revidirani strateški plan Državnog ureda za upravljanje državnom imovinom za razdoblje 2016. – 2018. (Državni ured za upravljanje državnom imovinom, 2016). Taj se strateški plan temelji na srednjoročnim ciljevima i smjernicama sadržanim u Strategiji upravljanja i raspolaganja imovinom u vlasništvu Republike Hrvatske u razdoblju 2013. do 2017. godine (NN 76/13). Ministarstvo državne

[1] Ministarstvo je ustrojeno u studenom 2016. godine, kao slijednik Središnjeg državnog ureda za upravljanje državnom imovinom (DUUDI).

imovine je kroz javno predstavljanje srednjoročnog projekta izgradnje i implementacije *Informacijskog sustava za upravljanje državnom imovinom* (ISUDIO) prezentiralo širi projekt višefazne podatkovne i programske nadogradnje postojećeg Registra državne imovine. Do sada nije ostvarena ideja da se kroz ISUDIO uz imovinu središnje države obuhvati i imovina jedinica lokalne i područne (regionalne) samouprave (u nastavku JLP(R)S).

Revidirani strateški plan[2] Ministarstva državne imovine za razdoblje 2018. – 2020. donosi redefinirane nazive reformskih mjera, glavnog cilja i opisa mjera, pravne / upravne instrumente i raspored provedbe (ključne točke ostvarenja i rokovi) reformskih mjera u odnosu na Nacionalni plan reformi 2017. i Strateški plan Ministarstva državne imovine za razdoblje 2018. – 2020. Strateškim planom[3] Ministarstva državne imovine za razdoblje 2019. – 2021. obuhvaćene su reformske mjere koje su sastavni dio Nacionalnog programa reformi 2017., među kojima je i glavna reformska mjera na području poboljšanja raspolaganja i upravljanja državnom imovinom.

Zadnju reviziju učinkovitosti upravljanja i raspolaganja nekretninama obavio je Državni ured za reviziju (DUR) za razdoblje 2012. – 2014. (s javnom objavom rezultata u ožujku 2016.). DUR je preporučio vođenje registra imovine JLP(R)S s istim sadržajem kao za državnu imovinu. DUR je predložio i izradu Strateškog plana upravljanja i raspolaganja imovinom (višegodišnje i operativne godišnje planove) po uzoru na državnu imovinu. S obzirom da JLP(R)S za to nemaju zakonske obveze, preporuke DUR-a su ostale na razini pisanih preporuka. Međutim, veliki je broj gradova zbog vlastitih potreba, ali i formalnog zadovoljenja preporuka, pristupio izradi traženih dokumenata.

Kvalitetnijem evidentiranju nekretnina gradova te upisom u zemljišne knjige (rješavanje pitanje vlasništva) ide u prilog i novi Zakon o upravljanju državnom imovinom (NN 52/18.). Iz zakona se može izdvojiti članak 70., u kojem stoji kako se nekretnine koje su se na dan 1. siječnja 2017. i koje su u zemljišnim knjigama upisane kao vlasništvo Republike Hrvatske, koristile kao

[2] Izvor: https://imovina.gov.hr/UserDocsImages/dokumenti/Prijedlog%20Plana%20upravljanja%20imovinom/Strategina%202018-2020.pdf

[3] Izvor: https://imovina.gov.hr/UserDocsImages/dokumenti/Izvjesca/Stratesk_plan_MIDIM_2019-2021.pdf

školske ustanove, domovi zdravlja, bolnice i druge ustanove kojima su osnivači JLP(R)S i koje se koriste u obrazovne i zdravstvene svrhe te ostala komunalna infrastruktura (groblja, mrtvačnice, spomenici, parkovi, trgovi, dječja igrališta, sportsko-rekreacijski objekti, sportska igrališta, društveni domovi, vatrogasni domovi, spomen-domovi, tržnice i javne stube) upisuju u vlasništvo jedinica lokalne samouprave na čijem području se nalaze odnosno u vlasništvo ustanove koja ih koristi ili njima upravlja i koja je vlasništvo nekretnine stekla temeljem posebnog propisa.

Unaprjeđenje sustava upravljanja imovinom temelji se na kvalitetnoj i točnoj evidenciji svih pojavnih oblika imovine, podacima koji karakteriziraju svaku pojedinu jedinicu imovine i na njihovoj vrijednosti. Da bi čelnici gradova mogli kvalitetno upravljati (raspolagati) nekretninama, na početku procesa moraju odgovoriti na dva pitanja: koliko imovine imaju i kolika je njezina vrijednost?

Procjena vrijednosti bitan je faktor upravljanja nekretninama što dokazuje podatak da 92% tijela lokalne vlasti redovito ažuriraju i procjenjuju vrijednost svojih nekretnina (Dent, 2014). Zakon o lokalnoj i područnoj (regionalnoj) samoupravi,[4] u čl. 67. imovinu definira kao: „Sve pokretne i nepokretne stvari te imovinska prava koje pripadaju gradovima čine njezinu imovinu. Gradovi moraju upravljati, koristiti se i raspolagati svojom imovinom pažnjom dobrog domaćina.“ Zakon o proračunu[5] u čl. 61. navodi da je „financijska i nefinancijska imovina u vlasništvu države i JLP(R)S. Za izvršavanje javnih službi i djelatnosti u javnom interesu država, gradovi mogu svojom imovinom osnovati ustanove, trgovačka društva i druge pravne osobe“.

U 2003. gotovo 70% imovine gradova nije bilo uredno evidentirano. Podaci su nepoznati, djelomični i neuređeni, a nije bila poznata ni vrijednost imovine i učinkovitost njezina korištenja. Učinkovito upravljanje imovinom gradova dobiva na značaju posebice u slučaju upravljanja nekretninama koje čine 80% vrijednosti imovine (Bertović et al., 2004). Slično je i u drugim državama. Tako 10% općina Novog Zelanda nisu imale evidentirane nekretnine od 1995. U SAD-u je samo 80% općina u uzorku Clevelanda imalo djelomično evidentirane nekretnine barem u inventarnim knjigama. Primjerice, u Rusiji još ne postoji propis koji jasno definira što su javna zemljišta u gradovima ovisno o različitim razinama vlasti. Albanija i

[4] NN 33/01, 60/01, 129/05, 109/07, 125/08, 36/09, 36/09, 150/11, 144/12, 19/13, 137/15
[5] NN 87/08, 136/12

Kirgistan uopće nemaju zakon o javnoj imovini (Kaganova, 2000). Od 1996. do 1998. godine samo 65% lokalnih samouprava u Novom Zelandu, odnosno 66% u Engleskoj i Walesu, imalo je informatizirane evidencije nekretnina (Bond et al., 1998). Od 1997. Washington, DC imao je duplicirane i nekonzistentne evidencije zgrada u svome vlasništvu, uz nepotpuni popis nekretnina koje su u zakupu. Razlog za kvalitetniji pristup upravljanju nekretninama nalazimo u činjenici kako većina gradova zbog nesređenog inventurnog stanja imovine ostvaruje relativno *nisku naplatu prihoda od nekretnina (zakup i najam),* a postoje i v*eliki nerazmjeri knjigovodstvene i tržišne vrijednosti nekretnina.* Usporedba tržišne i knjigovodstvene vrijednosti pojedine nekretnine pokazuje da odnos u prosjeku iznosi 5:1 (Bertović, 2004). *To znači da je vrijednost nekretnina u vlasništvu gradova pet puta veća od evidentirane, a toj vrijednosti treba dodati i vrijednost svih nekretnina koje će tek biti uvrštene uvrstiti u knjigovodstvene evidencije gradova* (Guszak, 2012). Nekretnine se često daju na korištenje bez odgovarajuće naknade - kroz indirektne subvencije. U narednim godinama mogu se očekivati promjene u pristupu upravljanja nekretninama gradova, osobito zbog slabijeg punjenja proračuna i financijskog opterećenja središnje države.

Gradovi u Republici Hrvatskoj raspolažu zatečenim površinama ureda, često su smješteni u neprimjerenim nekretninama, u užem centru na izuzetno vrijednim područjima, s ograničavajućim površinama i zahtjevnim pristupom (stare jezgre u centru, nedostatak parkirališnih mjesta). Vrlo su rijetki slučajevi kada se zgrada gradske uprave nalazi izvan stare gradske jezgre (npr. Zagreb i Split). Odabir upravnih zgrada u starim gradskim jezgrama ima opravdanje u važnosti institucije samouprave i povijesnom značenju nekretnine u kojoj se gradska uprava nalazi, kao što to pokazuju primjeri Varaždina, Osijeka, Karlovca, Samobora, Labina, Trogira i brojnih drugih gradova, posebice u usporedbi s korisnicima indirektnih subvencija[6] gradskih nekretnina (npr. udruge, socijalne ustanove ili pak političke stranke) za koje bi bilo povoljnije da djelatnost obavljaju u funkcionalnim prostorima uz racionalno korištenje.[7] Značajne površine su „zauzete“ i neracionalno se koriste. Takvi postupanjem izravno se umanjuju gradski proračunski prihodi potrebni za podmirenje režijskih i drugih troškova „zauzetih nekretnina“. Za korisnike indirektnih subvencija bilo bi povoljnije da od

[6] Tema pod naslovom *Indirektne subvencije* i pitanje korisnika indirektnih subvencija detaljno se obrađuju u 8. aktivnosti PRLS modela upravljanja imovinom.

[7] Neracionalno je korištenje poslovnog prostora u centru grada samo za sastanke koji se održavaju sat ili dva tjedno uz generiranje svih režijskih i drugih troškova.

lokalnih jedinica dobiju veća financijska sredstva za realizaciju svojih programa i sami pronađu odgovarajući prostor koji će racionalnije koristiti.

1.3. Ciljevi doktorskog rada

Na temelju definiranog predmeta istraživanja proizlazi osnovno istraživačko pitanje na koje disertacija treba pružiti odgovor:

- Upravljaju li gradovi učinkovito nekretninama u svojem vlasništvu?

Na to se pitanje prirodno nadovezuju ostala istraživačka pitanja:

- Koja obilježja gradova utječu na učinkovitost upravljanja nekretninama?
- Utječe li kvaliteta upravljanja na visinu proračunskih prihoda gradova od imovine?
- Utječe li veličina grada na učinkovitost upravljanja nekretninama?
- Utječe li geografski položaj gradova na učinkovitost upravljaju nekretninama?
- Jesu li gradovi koji su županijska središta učinkovitiji u upravljanju nekretninama u svom vlasništvu?
- Utječe li uvođenje PRLS modela upravljanja imovinom na povećanje učinkovitosti upravljanja nekretninama u hrvatskim gradovima koji su implementirali ovaj model?

Konačno, nakon definiranja teme i problema istraživanja te istraživačkih pitanja, određeni su i ciljevi istraživanja. Osnovni su znanstveni ciljevi istraživanja:

- empirijskom analizom istražiti koliko učinkovito hrvatski gradovi upravljaju nekretninama u svome vlasništvu
- empirijski istražiti koja obilježja gradova utječu na učinkovitost upravljanja nekretninama
- empirijski istražiti utječe li učinkovitost upravljanja nekretninama na visinu fiskalnih prihoda od nekretnina
- empirijski istražiti koliko geografski položaj i veličina utječu na učinkovitost upravljanja nekretninama u vlasništvu gradova.

Uz spomenute znanstvene ciljeve, potrebno je istaknuti i aplikativni cilj doktorskog rada:

- provesti analizu učinkovitosti upravljanja nekretninama u svim gradovima i razviti mjerilo uspješnosti

- teorijski razjasniti i sistematizirati učinke koji utječu na povećanje učinkovitosti gradova u upravljanju nekretninama u njihovom vlasništvu
- pružiti preporuke nositeljima politika i donositeljima odluka o načinima i metodama povećanja učinkovitosti u upravljanju nekretninama u vlasništvu gradova
- objasniti ulogu i značaj nekretnina u vlasništvu gradova
- analizirati modele i prakse upravljanja nekretninama u vlasništvu gradova
- objasniti važnost upravljanja nekretninama u gradovima u kontekstu lokalnog ekonomskog razvoja.

1.4. Hipoteze istraživanja

Sukladno navedenim istraživačkim pitanjima i ciljevima u doktorskom radu istraživanja testirat će se pet hipoteza. Svaka je hipoteza utvrđena temeljem teoretskih spoznaja i dosadašnjih empirijskih istraživanja uz testiranje primjenom prikladnih znanstvenih metoda. U nastavku se navode hipoteze i ukratko obrazlažu razlozi za njihovo utvrđivanje. Istraživačke hipoteze su:

H1: Gradovi u Republici Hrvatskoj neučinkovito upravljaju nekretninama u svojem vlasništvu.

Jedinice lokalne samouprave (u nastavku gradovi) nalaze se na određenom i jasno definiranom geografskom području s točno određenim granicama. Na navedenom prostoru nalaze se brojne nekretnine, kako zemljišta na kojima su smještene sve građevine, tako i svi drugi infrastrukturni objekti.

Nakon osnivanja, gradovi su od bivših teritorijalnih jedinica i podjelom starih općina dobili veliki broj nekretnina koje trebaju imovinsko-pravno zbrinuti, njima upravljati i voditi ih u poslovnim knjigama. Osim pravnim sljedništvom, gradovi su broj svojih nekretnina smanjivali i/ili povećavali ostalim oblicima raspolaganja (kupnjom, prodajom, darovanjem, itd.).

Zadnja revizija učinkovitosti upravljanja i raspolaganja nekretninama DUR-a za razdoblje 2012. – 2014. (DUR, 2016) obuhvatila je navedene tri vrste nekretnina (stanovi, poslovni prostori i zemljišta) JLP(R)S-a. Rezultati revizije pokazuju da više od 95% JLP(R)S-a ne upravljanju učinkovito svojim nekretninama.

Jedan od glavnih ciljeva rada je razraditi i ocijeniti učinkovitost upravljanja nekretninama gradova Republike Hrvatske uzimajući u obzir statistički bitne varijable koje mogu utjecati na učinkovitost i ukazati da postoji prostor za poboljšanje upravljanja s ciljem ostvarivanja boljih financijskih rezultata.

Slika 1.1 Gradovi u Republici Hrvatskoj

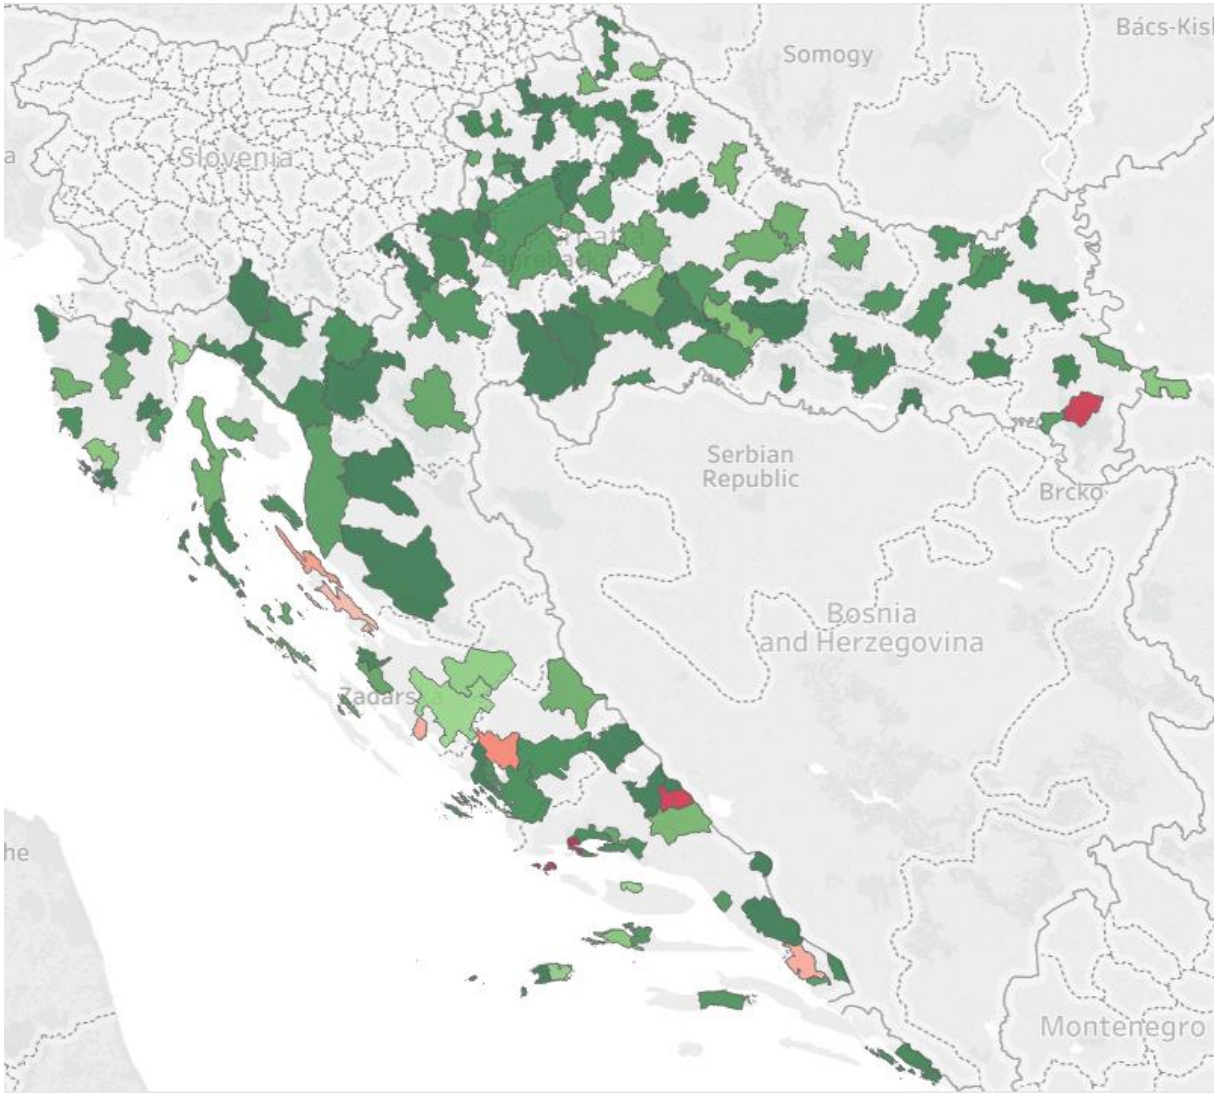

Izvor: Obrada autora

H2: Veliki gradovi učinkovitije upravljanju nekretninama u svojem vlasništvu u odnosu na ostale gradove.

Važan element analize je utvrditi učinkovitost hrvatskih gradova u upravljaju nekretninama u svome vlasništvu, a zatim ispitati upravljaju li veliki gradovi učinkovitije svojim nekretninama od malih i srednjih.

Veliki je grad je jedinica lokalne samouprave koja je ujedno gospodarsko, financijsko, kulturno, zdravstveno, prometno i znanstveno središte razvitka šireg okruženja i koja ima više od 35.000 stanovnika. Srednji grad je onaj s brojem stanovnika između 10.000 i 35.000, te mali grad s brojem stanovnika manjim od 10.000.

Veliki gradovi zakonom imaju definirano širi popis obaveza i usluga koje moraju pružati privatnim i pravnim osobama sa svojeg područja. Slijedom navedenog, imaju potrebu ustrojiti organizacijske jedinice te ih kadrovski ekipirati kako bi mogli izvršavati sve zakonom definirane obaveze i dužnosti. Veći broj zaposlenika gradske uprave s određenim stručnim znanjima i iskustvom koji su zaposleni u resornim upravnim odjelima i/ili odsjecima mogu doprinijeti kvalitetnijem upravljanju nekretninama koje su u vlasništvu grada.

Slika 1.2 Prikaz velikih gradova (zeleni) u odnosu na ostale gradove

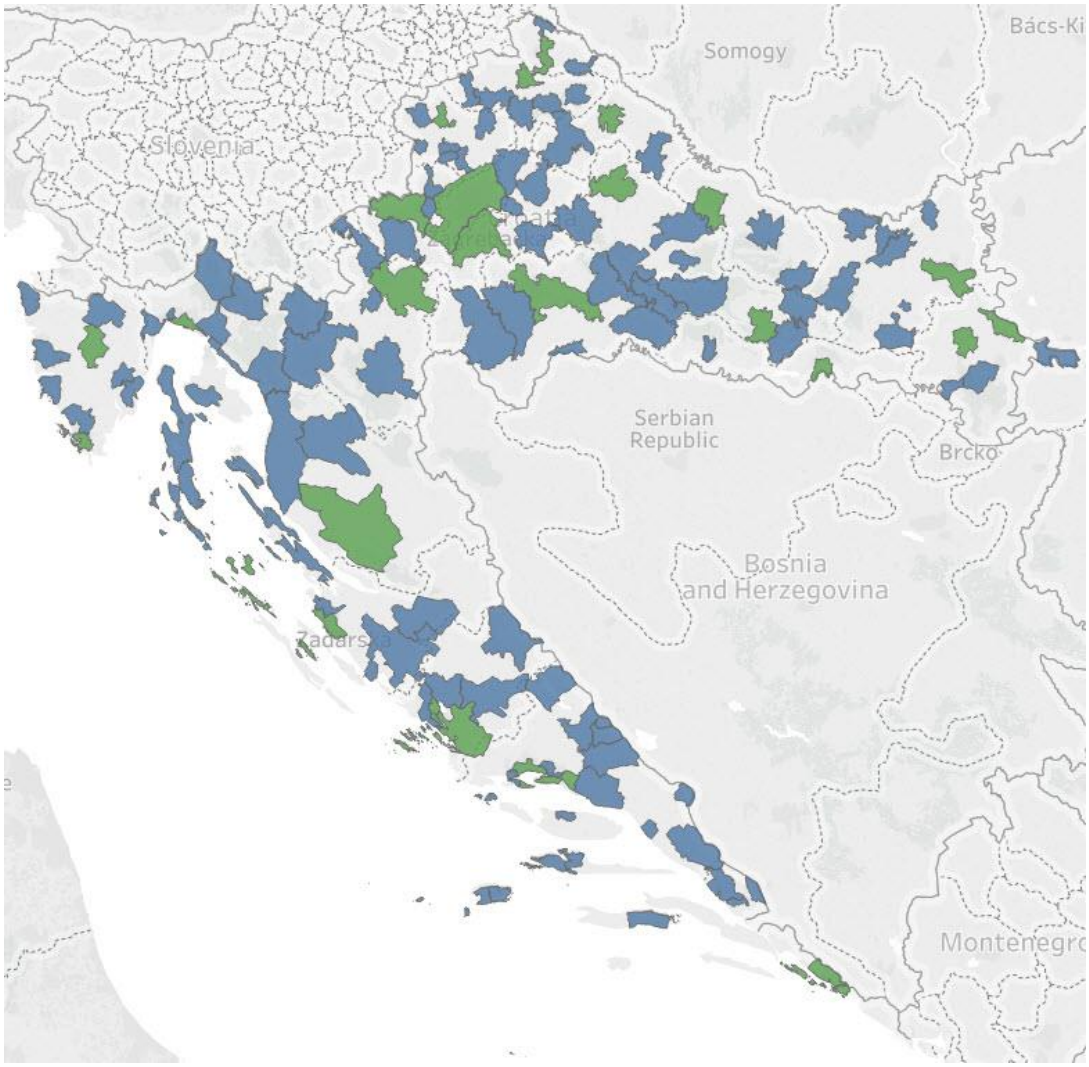

Izvor: Obrada autora

H3: Gradovi smješteni uz more učinkovitije upravljaju nekretninama u vlasništvu od gradova u unutrašnjosti.

Promatrajući zemljopisni položaj Republike Hrvatske, nastojat će se dokazati teza da primorski gradovi učinkovitije upravljaju i raspolažu nekretninama u svome vlasništvu od ostalih gradova. Primorski gradovi su oni koji se svojim rubnim granicama područja nalaze i/ili dodiruju morsku obalu. Gradovi koji lokacijom zadovoljavaju uvjet da su smješteni uz morsku obalu svojim položajem predstavljaju veći turistički potencijal u odnosu na gradove koji nisu smješteni uz more. Takav utjecaj možemo tumačiti kroz činjenicu da je Republika Hrvatska turistička zemlja koja u 2017. od prihoda u turizmu ostvaruje 19,7% BDP-a[8].

Slika 1.3 Prikaz gradova smještenih uz more

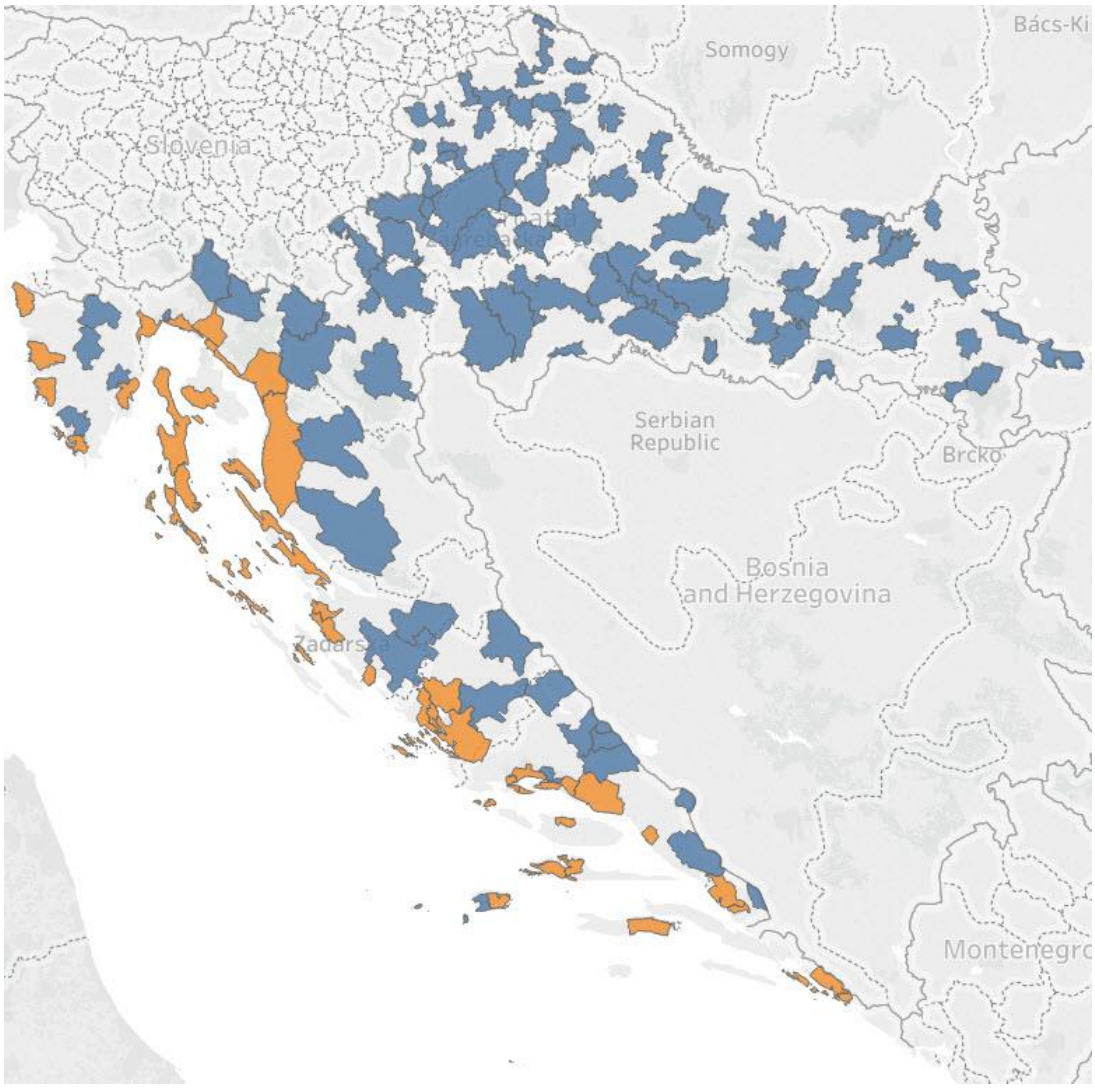

Izvor: Obrada autora

[8]Izvor: http://hrturizam.hr/prosle-godine-ostvaren-rast-prihoda-od-turizma-od-10-posto-sto-cini-196-posto-bdp/

Veća vrijednost nekretnina kao i potražnja za njima upravo na ovakvim lokacijama dolazi do izražaja i omogućuje vlasnicima bolje prinose. Sukladno tome gradovi koji su smješteni uz more uložit će veće resurse u svoje vlastite nekretnine kako bi maksimalno iskoristili njihov potencijal.

H4: Gradovi koji su središta županija učinkovitije upravljaju nekretninama u vlasništvu od ostalih gradova koji nisu županijska središta.

Gradovi županijska središta su jedinice lokalne samouprave koje (osim svojih redovnih djelatnosti zbog svoj položaja i normativnog uređenja) predstavljaju središta svojeg regionalnog područja čime takvim položajem jačaju društveni utjecaj i gospodarske aktivnosti u svom geografskom području. U gradovima koji su sjedišta županija, moguće je konzumirati usluge određenih funkcija središnje države koje su prenesene na županijska središta. Sukladno navedenom, u županijskim središtima nalaze se relevantne institucije, a samim time i nekretnine u funkciji upravljanja županijama.

Slika 1.4 Gradovi županijska središta

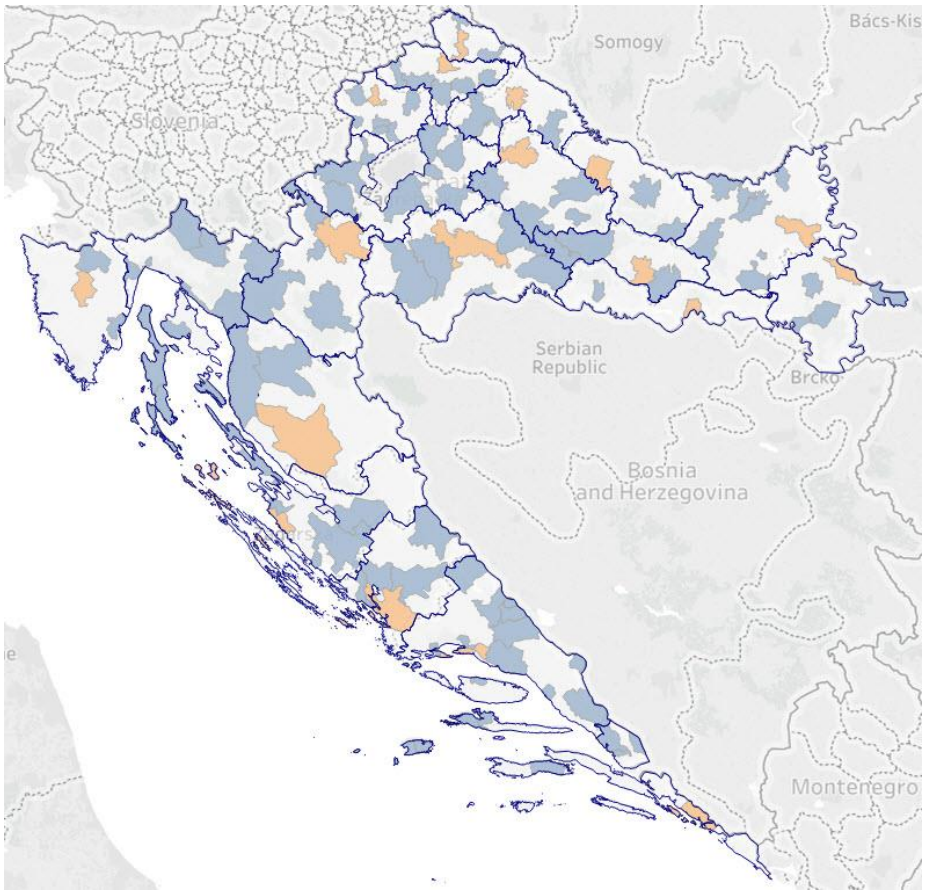

Izvor: Obrada autora

Ti su gradovi često i kulturna središta županija, čime se dodatno povećava iskorištenost nekretnina (kazališta, kina, muzeji, udruge i sl.). Navedeni gradovi često su i sjedišta poduzeća, a i većina svakodnevnog poslovanja koncentrirana je u njima, čime se povećava i broj gradskih i drugi prostora koji se koriste u poslovne svrhe.

H5: Upotrebom modela Upravljanja imovinom iz projekta Reforme lokalne samouprave moguće je povećati učinkovitost upravljanja nekretninama koje su u vlasništvu hrvatskih gradova.

U Republici Hrvatskoj je od 2001. do 2007. za potrebe Vlade implementiran projekt Reforme lokalne samouprave (PRLS) kojeg je razvio *The Urban Institute* iz Washingtona, po narudžbi USAID-a. Cilj je projekta bio ojačati upravljačke kapacitete lokalne samouprave kroz pet modula: (1) upravljanje financijama, (2) upravljanje imovinom, (3) gospodarski razvoj, (4) sudjelovanje građana i (5) informacijski sustavi. Model "Upravljanje imovinom" cjelovito je sagledavao upravljanje - od popisa imovine (inventura), analize statusa vlasništva i klasifikacije svih pojavnih oblika, prije svega nekretnina, kao i procjene tržišne vrijednosti nekretnina i učinkovitosti upravljanja mjerene stopom kapitalizacije. Za takvo mjerenje nužno je znati sve izvore prihoda i troškove koji se na nekretnini ostvaruju. Važan je dio modela sagledavanje postojećih odluka, sustava izvještavanja, načina organizacije i, u zadnjem koraku, strateško planiranje upravljanja imovinom gradova.

Upravljanje imovinom može se definirati kao skup aktivnosti koje sačinjavaju donošenje odluka o raspolaganju (kupnja, prodaja, darovanje, …) i korištenju imovine za potrebe korištenja vlasnika ili ulaganje kao investiciju a odnosi se na javni i privatni sektor (Bertović et al., 2004). Model za upravljanje imovinom temelji se na velikom međunarodnom iskustvu stečenom kroz dugogodišnji rad čiji su autori stručnjaci *The Urban Instituta* iz Washingtona na zahtjev Svjetske banke, a primjenjuje se u zemljama Europe i Azije (Kaganova et al., 2006), kao i u Hrvatskoj.

Tom hipotezom cilj je empirijski testirati utječe li implementacija tog modela na učinkovitije upravljanje nekretninama u vlasništvu hrvatskih gradova ovisno o njihovoj veličini.

1.5. Izvori podataka i metode istraživanja

U doktorskom radu koristit će se veći broj različitih znanstvenih metoda koje su opisane u nastavku.

Kvantitativna analiza u ovom radu temelji se na dva analitička pristupa – neparametarskoj metodi omeđivanja podataka (eng. Data Envelopment Analysis – DEA) te Tobit panel regresiji. Korištenjem metode DEA u prvom će se koraku izračunati pokazatelji učinkovitosti korištenja nekretnina u svakom gradu u uzorku. U drugom će se koraku Tobit panel regresijama analizirati ključne odrednice razlika u učinkovitosti korištenja nekretnina u svakom gradu u uzroku. Pritom je važno napomenuti kako će se gradovi prije analize podijeliti u tri skupine:

- veliki gradovi – gradovi koji su u promatranom razdoblju prosječno imali više od 35.000 stanovnika i /ili su bili sjedišta županija
- srednje veliki gradovi – gradovi koji su u promatranom razdoblju prosječno imali više od 10.000 stanovnika i manje od 35.000 stanovnika
- mali gradovi – gradovi koji su u promatranom razdoblju prosječno imali manje od 10.000 stanovnika.

Ta je podjela nužna kako bi se anulirao učinak značajnih razlika u gotovo svim varijablama koje su korištene u analizi između gradova. Grupiranje jedinica promatranja u logične i međusobno usporedive cjeline uobičajen je pristup u ekonomskoj analizi.

Prvi korak – izračun pokazatelja učinkovitosti korištenja nekretnina

Kako je prethodno napomenuto, u prvom koraku kvantitativne analize će se metodom omeđivanja podataka izračunati pokazatelj učinkovitosti upravljanja nekretninama u gradovima, koji će u radu biti označen kao θ. Metoda omeđivanja podataka, prema Coelli (1996), predstavlja skup modela i metoda koji se temelje na matematičkom programiranju. Podaci o izabranim inputima i outputima uvrštavaju se za sve analizirane donositelje odluka u linearni program koji predstavlja odabrani model analize omeđivanja podataka. Linearni program može se zapisati kao:

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

$$t.d. \sum_{r=1}^{s} u_r \, y_{rk} = 1 \tag{2}$$

$$\sum_{r=1}^{s} u_r \, y_{rj} - \sum_{i=1}^{m} y_{rj} \, x_{ij} \leq 0, j = 1, \dots, n \tag{3}$$

$$u_r \geq \varepsilon, r = 1, \dots, s$$

$$v_i \geq \varepsilon, i = 1, \dots, m$$

x_{ij} predstavlja količinu inputa, y_{rj} količinu outputa, v_i je ponder za pojedini input, u_r je ponder za pojedini output, a *k* je donositelj odluke, u slučaju ove disertacije grad.

Ovim načinom ocjenjuje učinkovitost određenog donositelja odluka unutar skupa usporedivih donositelja odluka, odnosno takvih koji pretvaraju inpute u outpute istovrsne onima promatranog donositelja odluka. Budući da se učinkovitost pojedinog donositelja odluka mjeri u odnosu na druge donositelje odluka, radi se o relativnoj učinkovitosti čija se vrijednost nalazi između 0 i 1, a odstupanja od 1 pripisuju se višku inputa ili manjku outputa.

Analiza omeđivanja podataka određuje empirijsku granicu učinkovitosti (granicu proizvodnih mogućnosti) omeđujući inpute odozdo, a outpute odozgo. S obzirom na to da je određuju (najbolji) postojeći donositelji odluka, granica učinkovitosti predstavlja ostvariv cilj prema kojemu trebaju težiti neučinkoviti donositelji odluka. Oni učinkovitost postižu projekcijom na granicu učinkovitosti. Ovim se, u odnosu na klasične statističke pristupe koji se temelje na prosječnim vrijednostima, analiza omeđivanja podataka temelji na ekstremnim opažanjima uspoređujući svakog donositelja odluka s onima najboljima.

DEA analiza će se u ovom radu temeljiti na jednom inputu i jednom outputu. Kao input će se koristiti vrijednost nekretnina, a kao output prihodi od nekretnina (podatci Ministarstva financija). Također, koristit će se model orijentiran na input, s pretpostavkom varijabilnih prinosa, budući da se takav pristup koristi u sličnim analizama (npr. Bogović, 2014).

Drugi korak – analiza odrednica učinkovitosti upravljanja nekretninama u gradovima

Budući da je cilj istraživanja analizirati odrednice učinkovitosti upravljanja nekretninama u hrvatskim gradovima kroz vrijeme, u ovom dijelu rada će se koristiti panel ekonometrijska analiza, koja podrazumijeva istovremenu analizu prostorne i vremenske komponente podataka. Prostornu komponentu čine gradovi – njih 126, a vremenska komponenta obuhvaća razdoblje od 2005. do 2016. godine; prema tome uzorak obuhvaća 1386 opažanja. S obzirom na prirodu podataka u ovoj će se analizi koristiti poseban oblik panel modela.

Radi se o modelu u kojem je zavisna varijabla latentna varijabla (varijabla čije se vrijednosti ne opažaju već je konstruirana), a u ovom modelu je ta varijabla pokazatelj učinkovitosti upravljanja nekretninama, čija se vrijednost kreće između 0 i 1. S obzirom na tako definirana ograničenja u radu se koristi Tobit model panel regresije, koji se još naziva i regresijski model s odrezanim vrijednostima (eng. *censored regression model*). Tobit panel regresijski model može se zapisati kao (Lionel, 2015[9]):

$$\theta_{it}^{*} = \beta X_{it} + \varepsilon_{it} \tag{4}$$

$$\theta^{*}{}_{it} = \begin{cases} 0 \; if \theta_{it}^{*} \leq 0 \\ 1 \; if \; \theta_{it}^{*} \geq 1 \\ \theta_{it}^{*} \; if \; 0 < \theta_{it}^{*} < 1 \end{cases} \quad i = 1, \dots, and \; t = 1, \dots, T \tag{5}$$

$\theta^{*}{}_{it}$ predstavlja zavisnu varijablu u modelu, pokazatelj učinkovitosti iz DEA analize, X_{it} skup nezavisnih, koji uključuje konstantu, glavne objašnjavajuće varijable (veličina gradova, zemljopisni položaj – lokacija, PRLS model) te skup kontrolnih varijabli (nezaposlenost stanovništva, fiskalni kapacitet, broj poduzetnika i transparentnost proračuna gradova), pri čemu su varijable detaljno objašnjene u tablici varijabli. β predstavlja vektor parametara, a ε_{it} predstavlja grešku relacije.

Kontrolne varijable (fiskalni kapacitet, broj poduzetnika, transparentnost proračuna gradova, nezaposlenost stanovništva) sa svojim vrijednostima mogu također utjecati na učinkovitost upravljanja nekretninama, kao npr.: a) pretpostavka je kako veći broj poduzetnika i zaposlenih u gradovima podrazumijeva veću (is)korištenost poslovnih prostora, odnosno veći angažman

[9] Izvor: http://journals.univ-danubius.ro/index.php/oeconomica/article/view/2833/2834

poslovnih prostora gradova, zatim b) gradovi koji su transparentniji bolje upravljaju resursima iz razloga što su izloženi većem nadzoru, kontroli i pritiscima (kako od strane građana prema gradovima, tako i od strane gradova prema svojim proračunskim korisnicima – ustanovama) i c) gradovi koji imaju snažniji fiskalni kapacitet mogu bolje održavati nekretnine koje stavljaju u uporabu. Indeks i odnosi se na prostornu dimenziju podataka, indeks t na vremensku dimenziju podataka.

Svi spomenuti sekundarni podaci analizirat će se pomoću znanstvenih metoda analize i sinteze, deskripcije, klasifikacije, komparacije i kompilacije. U nastavku se ukratko navode metode kojima će se testirati hipoteze.

H1: Gradovi u Republici Hrvatskoj neučinkovito upravljaju nekretninama u svojem vlasništvu.

Navedena hipoteza testirat će se metodom omeđivanja podataka na način da se za svaki grad izračuna pokazatelj učinkovitosti upravljanja nekretninama koji će poprimiti vrijednost između 0 (najniža učinkovitost) i 1 (najviša učinkovitost). U literaturi je utvrđeno da se jedinice odlučivanja, u ovom slučaju gradovi, koje imaju pokazatelj učinkovitosti $\theta > 0{,}9$ (npr. Barra i Zoti, 2014) mogu smatrati učinkovitim pa će se taj kriterij koristiti i u ovom istraživanju. Gradovi koji će imati rezultat parametra $\theta < 0{,}9$ smatrat će se neučinkovitima, gdje će se svi gradovi ovisno o skupini zasebno analizirati sukladno veličini parametra θ. Za svaku skupinu gradova analizirat će se postotak gradova koji se prema ovom pokazatelju mogu smatrati uspješnim te će se analizirati distribucija gradova prema veličini parametra θ. Grad Zagreb je uključen samo u skupini velikih gradova zbog čega se provodi normalizacija svih pokazatelja tako da on ne predstavlja *outlier*.

H2: Veliki gradovi učinkovitije upravljanju nekretninama u svojem vlasništvu u odnosu na ostale gradove.

Očitovanje o ovoj hipotezi temeljit će se na rezultatima analize omeđivanja podataka pri čemu će se analizirati veličina pokazatelja učinkovitosti upravljanja nekretninama u svakoj skupini gradova na način da će se detaljnije analizirati odstupanja svakog grada od granice učinkovitosti u svojoj skupini te će se uspoređivati medijani pokazatelja θ između skupina gradova po njihovoj veličini.

H3: Gradovi koji su smješteni uz more učinkovitije upravljaju nekretninama u svojem vlasništvu od gradova u unutrašnjosti.

Očitovanje o toj hipotezi zasnivat će se: (i) na temelju usporedbe medijana pokazatelja učinkovitosti upravljanja nekretninama dobivenim metodom omeđivanja podataka između skupina gradova (primorski nasuprot ostalim gradovima u svakoj skupini gradova prema veličini) i (ii) na temelju rezultata Tobit panel analize uključivanjem binarne varijable „lokacija“ u analizu, pri čemu će ona poprimiti vrijednost 1 za primorske gradove i 0 za ostale gradove.

H4: Gradovi koji su središta županija učinkovitije upravljaju nekretninama u vlasništvu od ostalih gradova koji nisu županijska središta.

Testiranje te hipoteze obavit će se temeljem: i) usporedbe medijana pokazatelja učinkovitosti upravljanja nekretninama dobivenim metodom omeđivanja podataka između skupina gradova (sjedišta županija nasuprot ostalim gradovima) i (ii) rezultata Tobit panel analize uključivanjem binarne varijable „sjedišta“ u analizu, pri čemu će ona poprimiti vrijednost 1 za gradove sjedišta županija i 0 za ostale gradove.

H5: Upotrebom modela Upravljanja imovinom iz projekta Reforme lokalne samouprave moguće je povećati učinkovitost upravljanja nekretninama koje su u vlasništvu hrvatskih gradova.

Testiranje te hipoteze temeljit će se na rezultatima Tobit panel analize uključivanjem binarne varijable „PRLS“ u analizu, pri čemu će ona poprimiti vrijednost 1 za gradove koji koriste PRLS model i 0 za ostale gradove.

1.6. Očekivani znanstveni doprinos doktorskog rada

U Republici Hrvatskoj ne postoji sustavno istraživanje koje analizira učinkovitost upravljanja nekretninama u vlasništvu gradova, te će predložena disertacija biti prvo istraživanje učinkovitosti upravljanja nekretninama na lokalnoj razini u Republici Hrvatskoj. Znanstveni doprinos kreirat će se kroz određivanje čimbenika koji doprinose učinkovitosti upravljanja nekretninama. Osim prikaza čimbenika koji doprinose, znanstveni doprinos bazirat će se i na razvoju alata i metoda za učinkovito upravljanje nekretnina u vlasništvu gradova.

U dosadašnjim istraživanjima uočen je nedostatak u istraživanjima i ocjeni uspješnosti upravljanja nekretninama u vlasništvu gradova Republike Hrvatske. Budući da ne postoji konkretan mjerljivi pokazatelj mjerilo (*benchmark*) upravljanja, najvažniji doprinos bit će razvoj mjerila uspješnosti, koje će za glavni cilj imati mjerenje i ocjenu učinkovitosti upravljanja nekretninama u vlasništvu gradova u Republici Hrvatskoj.

Dosadašnje studije u svijetu bavile su se učinkovitošću upravljanja nekretninama središnje države (Kask, 2014), zatim načinima korištenja nekretninama u vlasništvu lokalne samouprave (Wilson, 2013). Neki od radova istraživali su fiskalni kapacitet i prikupljanje prihoda od upravljanja nekretninama (Banner, 1995), dok se ostala većina radova fokusirala na analizu i način upravljanja nekretninama na lokalnoj razini (Kaganova et al., 2006).

Dio istraživanja odnosio se na analizu vrsta nekretnina kojima gradovi upravljaju i njihov pravni status (Kontrec, 2014), a dio je radova istraživao nekretnine u vlasništvu gradova i njihov način upravljanja odnosno metode evidentiranja (Guszak, 2007). Određeni dio studija usmjerio se na analizu i metodologiju usklađenja financijske vrijednosti nekretnina u vlasništvu lokalne samouprave (Vašiček, 2015).

Područje obuhvata doktorskog rada su svi gradovi Republike Hrvatske koji posjeduju 77% ukupne vrijednosti nefinancijske imovine (Državni ured za reviziju, Revizija učinkovitosti, 2016.). Navedeni obuhvat je iznimno značajan jer robusnost podatka osim kroz prostor dobivamo i kroz vrijeme. Također, robusnost se udvostručuje ispitivanjem kroz dvije metodologije. Analiza uspješnosti jedinica lokalne samouprave, odnosno samo jedne vrste – gradova, nalazi se i u drugim doktorskim i znanstvenim radovima (Bogović, 2014.).

Kako su nekretnine u vlasništvu gradova od velikog značaja, kako društvenog tako i ekonomskog, potrebno je promatrati sve čimbenike koji mogu utjecati na učinkovitost upravljanja navedenim nekretninama.

Pitanja raspolaganja nekretninama, određivanja vlasništva (Simonetti, 2010) ili drugih stvarnih prava uređena su brojnim zakonima i podzakonskim propisima. Međutim, tek je nekoliko zakona koji djelomično reguliraju ulogu gradova u upravljanju nekretninama. Sličan izazov

imaju i lokalne vlasti u drugim državama kada se susreću s nejasnim pravnim i institucionalnim okvirom za potporu upravljanju nekretninama (Trigunarsyah et al., 2010).

Postavljene hipoteze testirat će se primjenom dvaju analitičkih pristupa korištenjem sekundarnih podataka te će se generirati odgovori na pitanja koja su postavljena u skladu s ciljevima rada. U procesu izrade disertacije cilj je ponuditi odgovore na ključna pitanja istraživanja: koliko učinkovito hrvatski gradovi upravljaju nekretninama u svome vlasništvu, istražiti koja obilježja gradova utječu na učinkovitost upravljanja nekretninama te istražiti koliko geografski položaj i veličina utječu na učinkovitost upravljanja nekretnina u vlasništvu gradova.

Nekretnine jesu potencijal za lokalni ekonomski razvoj i alternativni izvor prihoda općina, gradova i županija (Kask, 2014). Upravljanje nekretninama u vlasništvu jedinica lokalne samouprave definira se kao strukturni proces koji nastoji osigurati najbolju vrijednost za novac iz imovinskih sredstava, a u službi strateških potreba organizacije u javnome sektoru (Jones et al., 2008).

Rezultati istraživanja koristit će se i kao podloga za izradu preporuka za Ministarstvo državne imovine, Vladu i gradove u svrhu kreiranja strateškog pristupa u području upravljanja nekretnina u vlasništvu gradova. Temeljem rezultata disertacije, menadžment jedinica lokalne samouprave moći će kroz utvrđene uzročno-posljedične veze poduzeti odgovarajuće inicijative. Također, svrha provođenja istraživanja je buđenje svijesti ključnih sudionika, čelnika gradova i njihovih djelatnika o važnosti kvalitetnog upravljanja nekretninama.

1.7. Struktura doktorskog rada

Doktorski rad podijeljen je u šest poglavlja.

U prvom uvodnom poglavlju definira se predmet i problem istraživanja, kao i postavljeni ciljevi. Obrazložit će se i svrha te važnost doktorskog rada, dati pregled postavljenih hipoteza, kao i metoda istraživanja koje će biti korištene u cjelokupnom istraživanju. U tom poglavlju navest će se izvori podataka za potrebe teorijskog i empirijskog dijela doktorskog rada te ukazati na znanstveni i aplikativni doprinos. Također će se pružiti kratak prikaz strukture rada.

U drugom se poglavlju predstavljaju temeljni pojmovi iz upravljanja nekretninama u lokalnoj samoupravi. U tom se poglavlju objašnjava uloga i značaj nekretnina u vlasništvu gradova, zatim modeli i prakse upravljanja te učinkovitost i utjecaj upravljanja nekretninama na uspješnost gradova.

U trećem poglavlju disertacije pruža se pregled istraživanja o upravljanju nekretninama lokalnih jedinica. Analizirat će se institucionalni okvir istraživanja, način praćenja vrijednosti i strukture nekretnina. Nastavno u ovom poglavlju dat će se prikaz revizije učinkovitosti, zatim koji je bio predmet i cilj, te kriteriji i ocjene.

Četvrti dio je analitički rad koji naglašava odabir i utjecaj izbora pokazatelja za mjerenje rezultata u javnom sektoru te obrazlaže formiranje pokazatelja koji odražavaju ukupne rezultate tih aktivnosti.

Nakon pregleda empirijskih istraživanja u petom poglavlju slijedi središnji dio istraživanja koji se odnosi na mjerenje i ocjenu učinkovitosti upravljanja nekretninama u vlasništvu gradova u Republici Hrvatskoj. U poglavlju se definiraju instrument istraživanja i karakteristike uzorka te se interpretiraju rezultati istraživanja. Nakon toga slijede rasprava o rezultatima i preporuka za buduća istraživanja.

Šesto poglavlje su zaključci doktorske disertacije i preporuke za daljnja istraživanja

2. TEMELJNE ZNAČAJKE I MODELI UPRAVLJANJA NEKRETNINAMA U VLASNIŠTVU GRADOVA

Učinkovito upravljanje prostornim resursima jedan je od glavnih čimbenika zdravog gospodarskog rasta. Produktivno upravljanje nekretninama od strane njihovih vlasnika očituje se kroz sustavnu i učinkovitu, kontinuiranu brigu koja rezultira ostvarivanjem planiranih rezultata odnosno ciljeva koje ostvaruju uporabom nekretnina u svom vlasništvu. Stoga ovaj rad promatra upravljaju li gradovi učinkovito svojim nekretninama. Prije svega, nužno je dobro definirati pojam nekretnina u smislu ovog rada, te njihovu ulogu i značaj.

2.1. Uloga i značaj nekretnina u vlasništvu gradova

Vlasništvo nad nekretninama predstavlja gradovima važan resurs kako bi u svom djelovanju ispunjavali sve obaveze koju su zakonom definirane i stvorile uvjete za kvalitetan život u lokalnoj zajednici.

2.1.1. Osnovna obilježja nekretnina u vlasništvu gradova

Učinkovito upravljanje prostornim resursima jedan je od glavnih čimbenika zdravog gospodarskog rasta. Produktivno upravljanje nekretninama od strane njihovih vlasnika očituje se kroz sustavnu i učinkovitu, kontinuiranu brigu koja rezultira ostvarivanjem planiranih rezultata odnosno ciljeva koje ostvaruju uporabom nekretnina u svom vlasništvu. Stoga ovaj rad promatra upravljaju li gradovi učinkovito svojim nekretninama. Prije svega, nužno je dobro definirati pojam nekretnina u smislu ovog rada, te njihovu ulogu i značaj.

Nekretnine predstavljaju pojavni oblik imovine koje su fizički smještene u prostoru, one su vezane za određeno područje i kao takve ne mogu biti jednostavno premještene s jedne na drugu lokaciju. Osim zemljišta, nekretninama se smatraju i drugi pojavni oblici koji su vezani za samo zemljište a predstavljaju određenu funkcionalnu cjelinu kao što su zgrade, ceste kao i sve ostale građevine Za razliku od pokretnina, nekretnine zbog svoje vrijednosti imaju drugačija pravila raspolaganja i uživanja. Prava vlasništva nad navedenim oblicima imovine (nekretninama) stječu se upisom u zemljišne knjige, dok se prava nad pokretninama stječu prodajom. Nekretnine, iako imaju predviđeni vijek trajanja, u pravilu period njihova korištenja može biti

dulji od prosječnog trajanja života njihovih vlasnika uz uvjet da se nekretnina održava. Nekretnine mogu biti korištene za osobne potrebe privatnih vlasnika a isto tako mogu biti korištenje u poslovne svrhe radi obavljanja djelatnosti poslovnog subjekta ili mogu služiti za iznajmljivanje.

No predmet ovog rada su nekretnine u vlasništvu gradova, te u tom kontekstu takve nekretnine služe za obavljanje komunalnih djelatnosti, djelatnosti odgoja i obrazovanja, sport i rekreaciju stanovništva te ostale aktivnosti iz djelokruga gradova.

Nekretnina je zbog svojih fizičkih svojstava i oblika vrlo teško otuđiva bez traga, te zbog svoje vrijednosti i pojavnog oblika predstavlja relativno sigurnu i stabilnu imovinu pogodnu kao instrument plaćanja kod različitih oblika kreditnog zaduživanja. U slučaju da dužnik ne namiri sve svoje obaveze po ugovorenom financiranju u dogovorenim rokovima, postoji mogućnost da vjerovnik naplati svoja potraživanja iz vrijednosti same nekretnine. Osim same nekretnine, svi oni njeni dijelovi koji čine funkcionalnu cjelinu ulaze u sastavni dio nje same i predstavljaju njenu ukupno vrijednost. Tako ako govorimo o kući, osim samog zemljišta i građevine, tu nekretninu čine i sve instalacije, oprema i ostali elementi koji su ugrađeni i koji čine tu cjelinu funkcionalnom.

U uvodu svoje knjige “Moderni menadžment nekretnina” Andreas Pfunur (2005.) zapaža izazov definiranja pojma nekretnina s obzirom na svoje višestruko značenje u govornom, ali i u znanstvenom području, te smatra kako je prije ekonomskog definiranja pojma nužno ga definirati kao pravni pojam s obzirom na to da se nekretnine prema vrsti i opsegu pravno određuju kao ekonomsko dobro u poslovnom prometu. Nadalje, autor raspravlja da je u okvirima pravne znanosti mnogo važniji pojam od nekretnina – zemljište, te da se nekretnine gotovo uopće i ne spominju. U općoj jezičnoj uporabi zemljište je povezana površina tla na nekom prostoru u prirodi, a najčešće je od drugih zemljišta fizički odvojena na različite načine: ogradom, zidom, živicom i sl. No takva definicija svakako nije dovoljno konkretna ni precizna jer je vezana uz promjenjive vanjske uvjete. Pfunur (2005.) napominje da “pravno gledano, pojam 'nekretnina' se ne primjenjuje”; ipak, u hrvatskom zakonodavstvu to nije slučaj. Naime,

Zakon o vlasništvu i drugim stvarnim pravima[10] nekretnine definira kao "čestice zemljine površine, zajedno sa svime što je sa zemljištem trajno spojeno na površini ili ispod nje". Istim zakonom definirano je ustavno i zakonsko najjače stvarno pravo – pravo vlasništva: „Pravo vlasništva je stvarno pravo na određenoj stvari koje ovlašćuje svoga nositelja da s tom stvari i koristima od nje čini što ga je volja te da svakoga drugoga od toga isključi, ako to nije protivno tuđim pravima ni zakonskim ograničenjima."

Također, pojam nekretnina definira Zakon o porezu na promet nekretnina[11] koji u članku 4. stavku 3. navodi: "nekretnine su zemljišta i građevine". Ova jednostavna zakonska definicija dobar je temelj za definiranje nekretnina u smislu i svrhu ovog rada gdje se nekretnine promatraju također kao zemljišta i građevine s tom razlikom da će se za konkretniji i jasniji prikaz istraživanja nekretnine gradova podijeliti na stanove, poslovne prostore i zemljišta.S ekonomskog stajališta, nekretnine su značajne s pozitivnim ili negativnim predznakom ovisno o tome prepoznaju li i u kojoj mjeri vlasnici svoj utjecaj jer kao posljedicu one donose u jednoj varijanti ekonomsku korist odnosno dobit, dok u drugoj neminovno donose ekonomsku štetu odnosno gubitke. S obzirom na činjenicu da je država u širem smislu vlasnik najvećeg broja nekretnina, tako su i jedinice lokalne (regionalne) i područne samouprave pa tako i gradovi vlasnici velikog broja različitih nekretnina od kojih su neke u funkciji ispunjenja svoje ekonomske i društvene svrhe, ali isto tako postoje mnogi slučajevi u kojima značajne nekretnine ne iskorištavaju svoj potencijal, tako neiskorištene propadaju te su predmet brige lokalnog stanovništva.

Vrijednost nekretnine zapravo nastaje tijekom vremena korištenjem nekretnine što kazuje da se vrijednost nekretnine ne može odrediti sama po sebi, već ovisi o učinkovitom ili neučinkovitom korištenju iste za što su svakako odgovorni njeni vlasnici odnosno u slučaju gradova predstavnici vlasnika. Pfnur (2005.) ovu činjeničnu pojavu opisuje na način da nekretnine nije moguće promatrati samo kroz inženjersko-znanstveno trodimenzionalno razgraničenje nego treba dodati i vrijeme kao integralnu sastavnicu ekonomske definicije nekretnina: Nekretnina kao dugoročna prostorna i novčana vrijednost (engl. *Real estate as space and money over time).* S obzirom na navedeno, nekretnine postaju isplativi financijski oblik tek nakon što se prostorno-vremenske jedinice pretvore u novčano-vremenske jedinice.

[10] NN 91/96, 68/98, 137/99, 22/00, 73/00, 129/00, 114/01, 79/06, 141/06, 146/08, 38/09, 153/09, 143/12, 152/14
[11] NN 115/16, 106/18

Portfelj nekretnina gradova može uvelike olakšati ili otežati obavljanje njihovih osnovnih funkcija odnosno poslova iz samoupravnog djelokruga. Za ostale poslove iz samoupravnog djelokruga upravljanje nekretninama ima neposredan učinak na način da nekretnine u vlasništvu pune proračun stvarajući više prihoda od rashoda ili prazne proračun stvarajući više troškova nego prihoda. Stoga je učinkovito upravljanje nekretninama od strane vlasnika, u ovom slučaju gradova, ključno za ostvarivanje svoje ekonomske i društvene svrhe.

2.1.2. Vrste nekretnina

Predmet ovog rada je ocjena upravljanja nekretninama u vlasništvu gradova. Nekretnine predstavljaju vrstu nefinancijske imovine s najvećom vrijednošću kojom raspolažu i upravljaju gradovi.

Prema Pfnuru (2005.) nekretnine su privredna dobra u obliku zemljišta odnosno zemljišno-jednakih prava, zgrada i pribora čiji odnosi troškova i dobiti tijekom vremena utječu na ostvarivanje ciljeva privrednih subjekata. Pritom, s obzirom na mjerilo mogućnosti ekonomskog korištenja, mogu biti djelomična količina kao i skupina zemljišta, zemljišno jednakih prava ili njihovih važnih sastavnih dijelova u smislu građanskog prava.

Kako bi jasnije razgraničili ovu definiciju, nekretnine je potrebno klasificirati prema različitim kriterijima.

Tablica 2-1 Kriteriji razlikovanja nekretnina

Kriterij razlikovanja:	Primjeri:
Predmet	Zemljišta, poslovni prostori, stanovi
Vrsta korištenja	Privatno, poslovno (uredske površine, skladišne površine, proizvodne površine, izložbene površine, prodajne površine, turističke površine, površine za zabavu i rekreaciju, prometne površine)
Veličina objekta	Velik, srednji, mali
Položaj	Položaj u užem centru grada, položaj u širem centru grada, položaj na periferiji, položaj izvan grada
Vlasnički odnosi	1. Vlasnik udjela, vlasnik, zakupnik, korisnik *leasinga*. 2. Neriješeni vlasnički odnosi
Starost	Novogradnja, stara gradnja, modernizirana stara gradnja

Izvor: Pfnur (2005.), obrada i prilagodba autora

Prema Zakonu o najmu stanova, „stanom se smatra skup prostorija namijenjenih za stanovanje s prijeko potrebnim sporednim prostorijama koje čine jednu zatvorenu građevinsku cjelinu i imaju poseban ulaz". To znači da stan prvenstveno promatramo kao građevinsku cjelinu (gledano tehničke uvjete za stanove prema kriteriju građevinskih propisa), a zatim kao uporabnu cjelinu po kriteriju imovinsko-pravnih propisa.

Zakon o zakupu i kupoprodaju poslovnog prostora u članku 2. stavku 2. navodi da „poslovnim prostorom u smislu ovog Zakona smatraju (se) poslovna zgrada, poslovna prostorija, garaža i garažno mjesto." Zakon također kroz sljedeća četiri članka definira poslovnu zgradu, poslovnu prostoriju, garažu i garažno mjesto. Poslovna je zgrada namijenjena obavljanju poslovne djelatnosti ako se pretežito koristi u tu svrhu. Poslovna prostorija dio je poslovne ili stambene zgrade namijenjena obavljanju poslovne djelatnosti, a obično ima zaseban ulaz i samostalna je

uporabna cjelina. Garaža je prostor za smještanje vozila. Garažno mjesto je prostor za smještanje vozila unutar garaže.

Prema 3. članku Zakona o zemljišnim knjigama "zemljište (je) u smislu ovog Zakona dio zemljine površine koji je u katastru zemljišta označen posebnim brojem i nazivom katastarske općine u kojoj leži (katastarska čestica)". Drugi stavak istog članka navodi da "sve što je sa zemljištem trajno spojeno na površini ili ispod nje u pravnom smislu sastavni dio zemljišta i ako zakonom nije drugačije određeno, dijeli njegovu pravnu sudbinu". Građevinsko zemljište definirano je 3. člankom Zakona o prostornom uređenju kao "zemljište unutar granica građevinskog područja te zemljište izvan građevinskog područja obuhvaćeno građevnom česticom na kojoj je izgrađena građevina". Zakon o poljoprivrednom zemljištu u 3. članku definira poljoprivredno zemljište kao "pojedino zemljište izvan građevinskog područja koje je po načinu upotrebe u katastru opisano kao oranice, vrtovi, livade, pašnjaci, voćnjaci, maslinici, vinogradi, ribnjaci, trstici i močvare, kao i drugo zemljište koje se može privesti poljoprivrednoj proizvodnji".

2.1.3. Uloga upravljanja nekretninama u upravljanju gradovima

Zakon o lokalnoj i područnoj (regionalnoj) samoupravi definira jedinice lokalne samouprave u Hrvatskoj kao gradove i općine. Grad je mjesto u kojem se nalazi sjedište županije, kao i svako mjesto s više od 10.000 stanovnika koje predstavlja urbanu, povijesnu, prirodnu, gospodarsku i društvenu cjelinu. Grad u smislu jedinice lokalne samouprave može uključivati i prigradska naselja koja su uključena u gospodarsku i društvenu cjelinu grada i s njime povezana dnevnim migracijskim kretanjima i lokalnim potrebama stanovništva. Iznimno, na temelju posebnih povijesnih, gospodarskih ili geoprometnih razloga, mjesto može dobiti status grada iako ne zadovoljava ostale kriterije. Grad se sastoji od tri organizacijske cjeline: gradsko vijeće, izvršna vlast (gradonačelnik) i gradska uprava. Ovlasti prve dvije cjeline uključuju donošenje odluka, a treća je zadužena za provedbu tih odluka sukladno zakonima i podzakonskim propisima.

Isti zakon gradonačelnike ovlašćuje da upravljaju nekretninama u vlasništvu grada, te prihodima i rashodima koje ostvaruju, prema statutu i zakonu. Gradonačelnici donose odluke o stjecanju i otuđivanju nekretnina u iznosu od maksimalno 0,5% prihoda bez primitaka ostvarenih prethodne godine, s time da iznos ne smije premašivati milijun kuna. U slučaju većeg iznosa, na temelju prijedloga gradonačelnika takve odluke donosi predstavničko tijelo (gradsko

vijeće, odnosno, gradska skupština) što pokazuje da upravljanje nekretninama spada među najvažnije funkcije grada.

Gradovi su samostalni u obavljanju poslova lokalnog značaja koji ispunjavaju potrebe građana, a nisu Ustavom ili zakonima dodijeljeni državnim tijelima. To su poslovi koji se odnose na: uređenje naselja i stanovanje, prostorno i urbanističko planiranje, komunalno gospodarstvo, brigu o djeci, socijalnu skrb, primarnu zdravstvenu zaštitu, odgoj i osnovno obrazovanje, kulturu, tjelesnu kulturu i šport, zaštitu potrošača, zaštitu i unapređenje prirodnoga okoliša, protupožarnu i civilnu zaštitu, promet na svom području i na ostale poslove sukladno s posebnim zakonima.

Za obavljanje navedenih poslova i djelatnosti potrebna su određena sredstva i imovina koja uključuje sve pokretne i nepokretne stvari te imovinska prava u vlasništvu grada. Grad svojom imovinom treba upravljati, koristiti se i raspolaganu prema načelu dobrog domaćina. To znači da je upravljanje dobrima u vlasništvu grada izloženog povećanoj pažnji i vođenju brige upravitelja o javnom interesu kojem ta imovina služi.

Što se smatra javnim interesom razrađeno je kroz niz zakona: Zakon o proračunu, Zakon o državnoj reviziji, Zakon o javnoj nabavi, Zakon o vlasništvu i drugim stvarnim pravima, Zakon o zakupu i kupoprodaji poslovnog prostora, Zakon o prostornom uređenju i gradnji. Pravo vlasništva je stvarno pravo na određenoj stvari koje ovlašćuje svoga nositelja (u ovom slučaju gradove) da s tom stvari i koristima od nje čini što ga je volja, te da svakog drugog od toga isključi ako to nije protivno nekom tuđem pravu ili nekom zakonskom ograničenju. Upravo ta ograničenja definiraju pravo posjedovanja, uporabe, korištenja i raspolaganje konkretnom predmetnom stvari.

Zakon o lokalnoj i područnoj (regionalnoj) samoupravi kao prihode grada propisuje gradske poreze, prirez, naknade, doprinose i pristojbe, novčane kazne i oduzetu imovinsku korist, udio u zajedničkim porezima s Republikom Hrvatskom, sredstva pomoći i dotacije Republike Hrvatske izdvojena iz državnog proračuna, prihode od stvari u njezinom vlasništvu i imovinskih prava, te druge određene Zakonom. Zato su prihodi od upravljanja nekretninama važni za gradski proračun i često su značajan faktor u uspješnome funkcioniranju grada. Lokalnim jedinicama u tranzicijskim zemljama zajedničko je obilježje velik broj nekretnina u vlasništvu koje često čine i do 80% ukupne vrijednosti imovine lokalne jedinice, a istodobno su najmanje

iskorišten resurs koji lokalna jedinica ima na raspolaganju. Vrijednost nepokretne imovine često je značajno visoka u odnosu na godišnji proračun što ukazuje na velik potencijal za povećanje prihoda na temelju nekretnina i iskorištavanje imovine za uspješno obavljanje poslova lokalne samouprave. (Guszak, 2008.)

Istraživači se nisu usuglasili oko podrijetla upravljanja nekretninama, ali postoji suglasje da se upravljanje razvilo iz drugih disciplina. Primjerice, Edwards (2009) raspravlja o tome da je koncept upravljanja nekretninama relativno nov te da obuhvaća one aktivnosti koje su provođene i u prethodnim razdobljima, a razvile su se tijekom nekoliko desetljeća industrijskog doba. Bez obzira na podrijetlo upravljanja nekretninama, organizacije javnog i lokalnog sektora počele su cijeniti njegove pozitivne učinke. Tijekom razvojne faze, upravljanje nekretninama prihvaća i implementira druge discipline i tehnike. Upravljanje nekretninama je potencijalno moćan alat za stvaranje dodane vrijednosti, smanjenje troškova održavanja i upravljanja te poboljšanja kvalitete života u zajednici.

Upravljanje nekretninama u gradovima diljem svijeta donosi nekoliko vrlo sličnih ili istih okolnosti. Procesom decentralizacije lokalne samouprave gradovi su trenutačno postali "nekretninski divovi", odnosno novi nositelji vlasništva nekretnina. Međutim, navedenu transformaciju ne prati povećanje prihoda potrebnih za uredno evidentiranja promjena i održavanja navedenih nekretnina. Postoji veliki raskorak između potražnje za javnim uslugama i dostupnosti nekretnina kao alata koji utječu na uspješnost pružanja javnih usluga.

Dodatna potvrda važnosti brige o nekretninama lokalnih jedinica jesu vrijednosti gradskih portfelja. Vrijednost nepokretne imovine Grada Slatine na dan 31.12.2004. godine bila je 44.760.000,00 kn. Ukupna vrijednost oko 6000 nekretnina gradova Varaždina, Karlovca i Splita procijenjena je na 1 milijardu USD (Guszak, 2008., PRLS, 2006.).

Upravljanje bi trebalo biti korisnički usmjereno, učinkovito, razvidno i participirajuće radi postizanja što boljih rezultata poslovanja. Uloga javnog menadžmenta promatra se kao prihvaćanje odgovornosti za organizirano i učinkovito djelovanje u području upravljanja resursima i poslovanjem države. (Grubišić, 2009.)

Jedinice lokalne samouprave u Republici Hrvatskoj u vlasništvu imaju veliki broj različitih oblika imovine. Nekretnine (zemljišta, poslovni prostori i stanovi) predstavljaju najvrjedniji

pojavni oblik u portfelju nefinancijske imovine. Navedene vrste nekretnina (nefinancijska imovina) posredno su vlasništvo svih građana, zbog čega je bitno osigurati njihovo učinkovito upravljanje. Gradovi su (uz općine) dio javne uprave odnosno javne vlasti koja je s obzirom na kriterij posrednosti najbliža građanima odnosno odluke koje se donose na ovoj razini najuočljivije su i veoma važne za svakodnevni život velikog broja ljudi. Iz toga možemo zaključiti i da je upravljanje imovinom, konkretnije nekretninama u vlasništvu gradova važno za kvalitetu života lokalnog stanovništva i njihov prosperitet.

2.2. Modeli i prakse upravljanja nekretninama gradova

Promatrajući inozemne primjere kroz različite kontinente, države posjeduju određene specifičnosti prilikom upravljanja nekretninama. Specifičnost između pojedinih država pa i samih lokalnih jedinica proizlazi iz prostornih, lokacijskih, regulatornih i drugih čimbenika koji utječu na upravljanje nekretninama.

2.2.1. Pregled inozemnih primjera upravljanja nekretninama gradova

- **Njemačka**

Javni sektor je u Njemačkoj vlasnik najvećeg portfolija nekretnina. Zbog velikog broja različitih usluga koje pruža, i nekretnine u njegovom vlasništvu su diversificirane. Njihova ukupna vrijednost procjenjuje se na oko 800 milijardi eura (Kaganova, 2006.), ali valja naglasiti da ti podaci nisu posve pouzdani ni precizni.

S obzirom na enormnu vrijednost nekretnina, enormni su i troškovi upravljanja tom imovinom, te nakon cijene rada čine drugi najveći trošak u njemačkim javnim kompanijama, te čini između 15 i 20 posto ukupnog budžeta administrativnih jedinica. Procjenjuje se da bi optimizacija sustava upravljanja nekretninama mogla rezultirati uštedama između 10 i 15 posto ukupnih troškova upravljanja nekretninama. Uobičajeni nekretninski portfelj lokalnih jedinica vlasti uključuje škole, vrtiće, uredske prostore, objekte za rekreaciju, bolnice i muzeje. Objekti poput zatvora, vojarni, sveučilišnih kampusa i zgrada pod upravom su državne vlasti.

Osnovna razlika između upravljanja nekretninama u privatnom i javnom sektoru je ta da javni sektor mora prepoznati koji je javni interes i na temelju toga djelovati kako bi ga zadovoljio. Misija javnog sektora uključuje širok spektar različitih aktivnosti, od organiziranja obrazovnog

sustava, preko brige o urbanom razvoju do upravljanja javnim parkovima. Upravljanje javnim nekretninama je aktivan proces orijentiran na rezultate koji u obzir uzima i ekonomski i javni interes.

U Njemačkoj funkcionira 527 lokalnih jedinica uprave i samouprave (distrikti, nezavisni gradovi, parohije) koji imaju više od 50.000 stanovnika. Stoga je ta populacija od 82,4 milijuna Nijemaca uzorak populacije najvećeg istraživanja o upravljanju imovinom lokalnih vlasti u Njemačkoj, koju su proveli Karl-Werner Schulte i Christian Ecke, a koje je objavljeno u knjizi Olge Kaganove i Jamesa McKellara: Managing Government Property Assets (2006.)

Kako je bilo potrebno analizirati operativne zadatke i učinke upravljanja javnim nekretninama, podaci su prikupljeni višedimenzionalnim pristupom pomoću dva upitnika. Prvi se fokusirao na strategiju i organizaciju, a drugi na operacionalizaciju. Podaci su prikupljani telefonski u anketama čije je trajanje bilo između 20 i 80 minuta. Ukupno je prikupljeno 215 odgovora, 116 u prvom upitniku, te 99 s drugim. Ovo ispitivanje obuhvatilo je slučajnim odabirom jedinice lokalne vlasti koje zastupaju između 19 i 25% ukupnog stanovništva Njemačke.

Istraživanje je pokazalo da je stjecanje nekretnina skupo, te kada postanu vlasništvo često su nefleksibilne za korištenje. Također, održavanje i upravljanje nekretninama je skupo i zahtijeva značajno velik utrošak vremena. Stoga se nekretninama u javnom vlasništvu pristupa s pažljivim strateškim pristupom. Kako bi dokazali ili opovrgnuli ovu tezu, u upitniku je postavljeno pitanje o strateškoj ulozi nekretnina u vlasništvu jedinica lokalne vlasti. Prema provedenoj analizi odgovora većina jedinica lokalnih vlasti koje su sudjelovale u istraživanju na nekretnine gledaju prvenstveno kao na trošak (51%), dok ih strateškim resursom smatra samo 21%. Ova činjenica pokazuje kako se nekretninama u Njemačkoj ipak upravlja s manje strateške pažnje. Odluke se često donose reaktivno kada troškovi izmaknu kontroli odnosno premaše očekivane. Dugoročno, ovakav pristup dovodi do problema značajne nedovoljne iskorištenosti lokalnih resursa.

Grafikon 2-1 Strateška uloga nekretnina u vlasništvu lokalnih vlasti

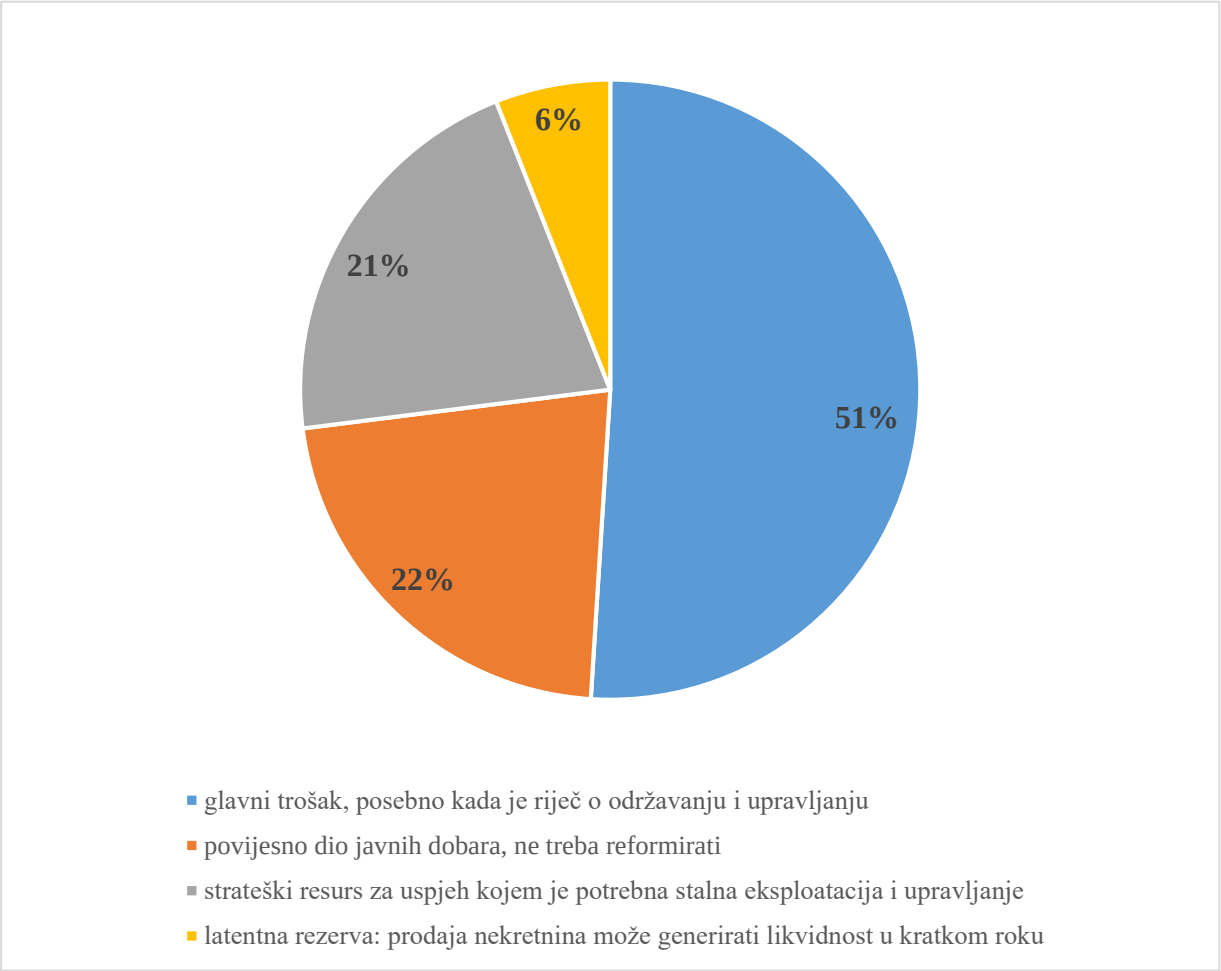

Izvor: Kaganova (2006.), obrada: autor

Kada se raspravlja o upravljanju nekretninama u javnom vlasništvu, u literaturi se često postavlja pitanje trebaju li jedinice lokalne vlasti uopće posjedovati nekretnine. U prošlosti je situacija na tržištu nekretnina bila drugačija i nekretnine koje mogu zadovoljiti potrebe za ispunjenje usluga koje pružaju jedinice lokalne vlasti nisu bile u ponudi za najam što je jedan od glavnih razloga zašto su danas portfoliji nekretnina u vlasništvu država najveći i najkompleksniji.

Danas je situacija poprilično drugačija i diljem svijeta postoje brojni primjeri u kojima privatni iznajmljivači nude prostore prikladne za širok spektar javnih usluga, od škola do zatvora. Iz navedenog je razvidno kako operativni razlozi za posjedovanje tolikog broja različitih nekretnina sve više gube na značaju. Istraživači su u istraživanju obradili i ovu temu. Uprave njemačkih jedinica lokalnih vlasti u ovom važnom pitanju su podijeljene. Oko polovice ispitanika izražava stav da je potrebno posjedovati sve ili većinu nekretnina u kojima se odvijaju

usluge koje njihove razine vlasti pružaju, dok druga polovica koja ipak čini većinu (51%) smatra kako bi trebali posjedovati samo manji dio ili uopće ne bi trebali imati nekretnine u vlasništvu jedinica lokalnih vlasti.

Grafikon 2-2 Procjena potrebe za vlastitim javnim nekretninama

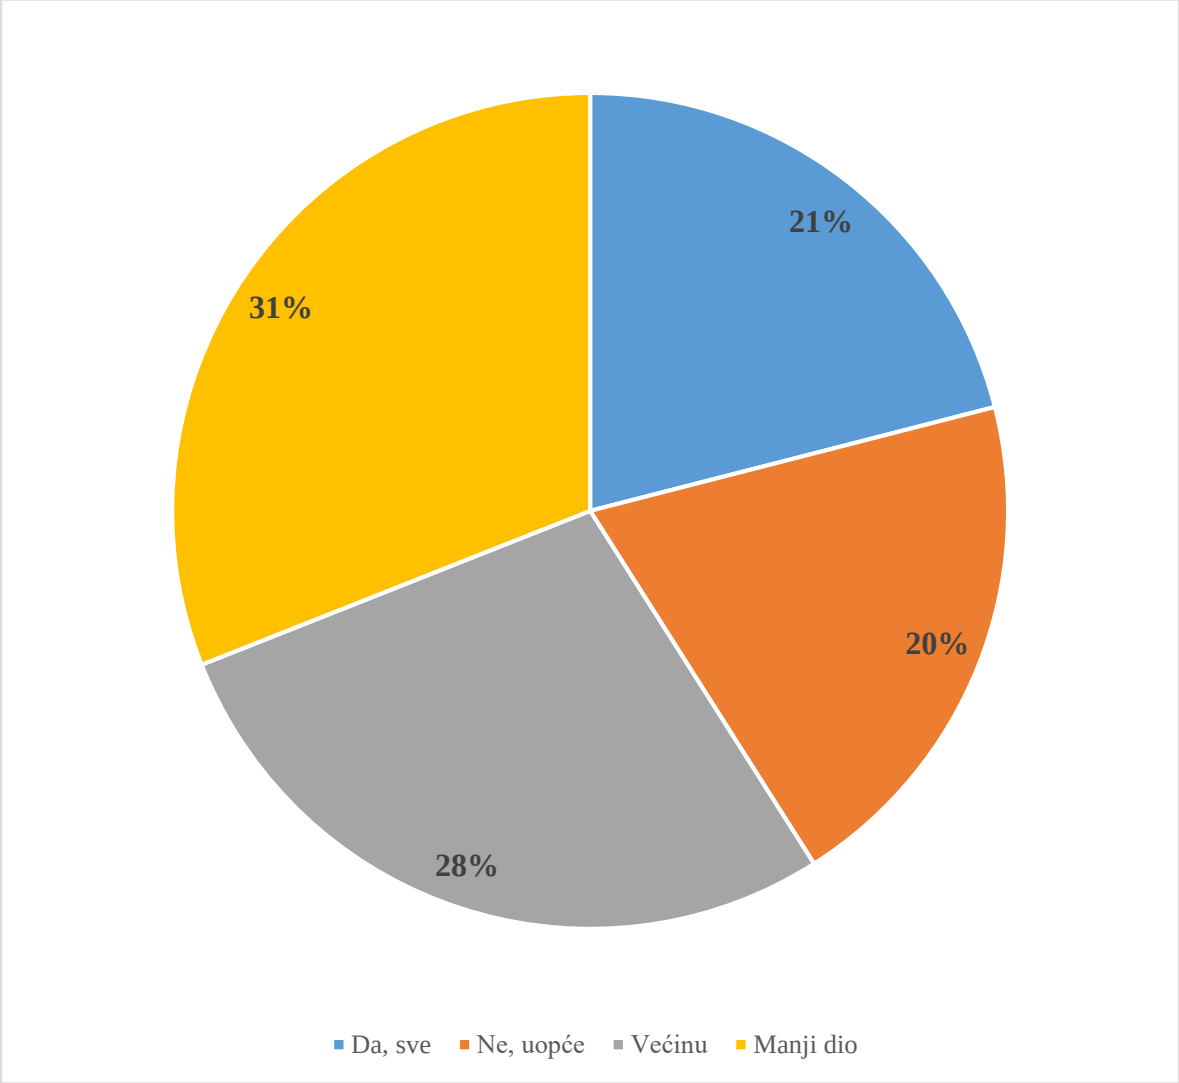

Izvor: Kaganova (2006.), obrada: autor

Kada je riječ o novim projektima, čak 90% predstavnika lokalnih vlasti odgovorilo je da planira projekte za razvoj i poboljšanje funkcije upravljanja nekretninama. Ipak, realizacija poprilično zaostaje za planiranim. Nešto više od polovine (53%) ispitanika je započelo takav projekt u posljednjih 5 godina, a od te polovice samo je trećina (34%) uspješno završena.

Grafikon 2-3 Broj započetih projekata upravljanja javnim nekretninama u zadnjih 5 godina

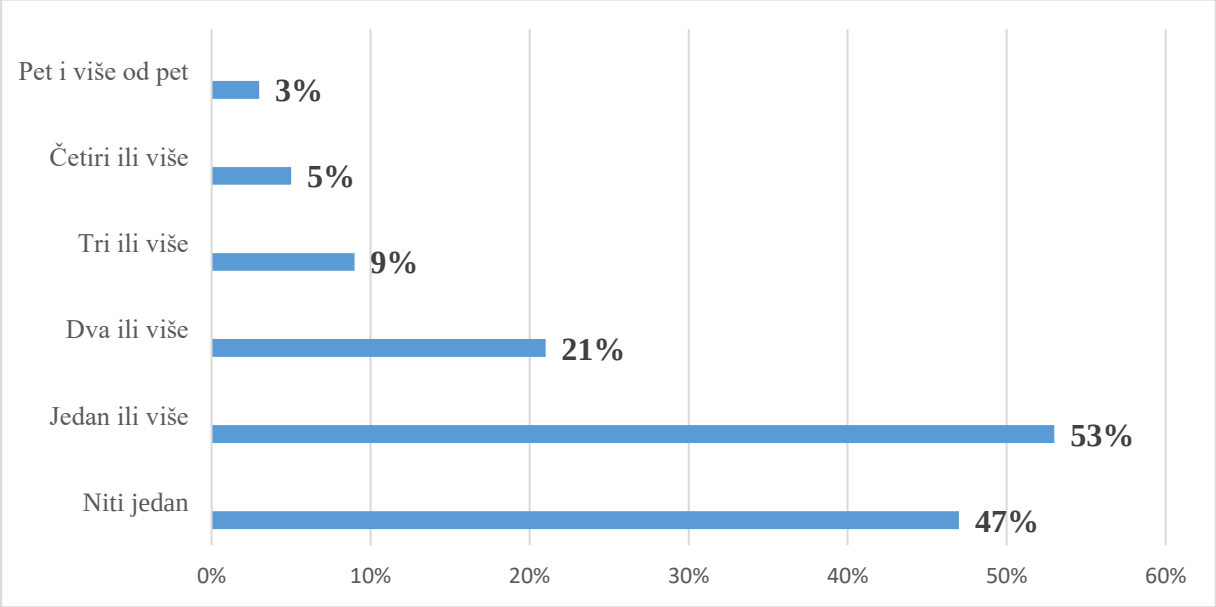

Izvor: Kaganova (2006.), obrada: autor

Gledajući na institucionalnu strukturu lokalnih vlasti u Njemačkoj, to nije iznenađenje. Operativno povezani poslovi u vezi s nekretninama obično su fragmentirani na više različitih odjela, dok odluke vezane uz proračun ovise o dugoročnim ciklusima planiranja pod kontrolom političkih tijela. Takva podjela proračuna i odgovornosti u provedbi rezultira s vrlo neučinkovitim procesom donošenja odluka.

Grafikon 2-4 Status provedenih projekata

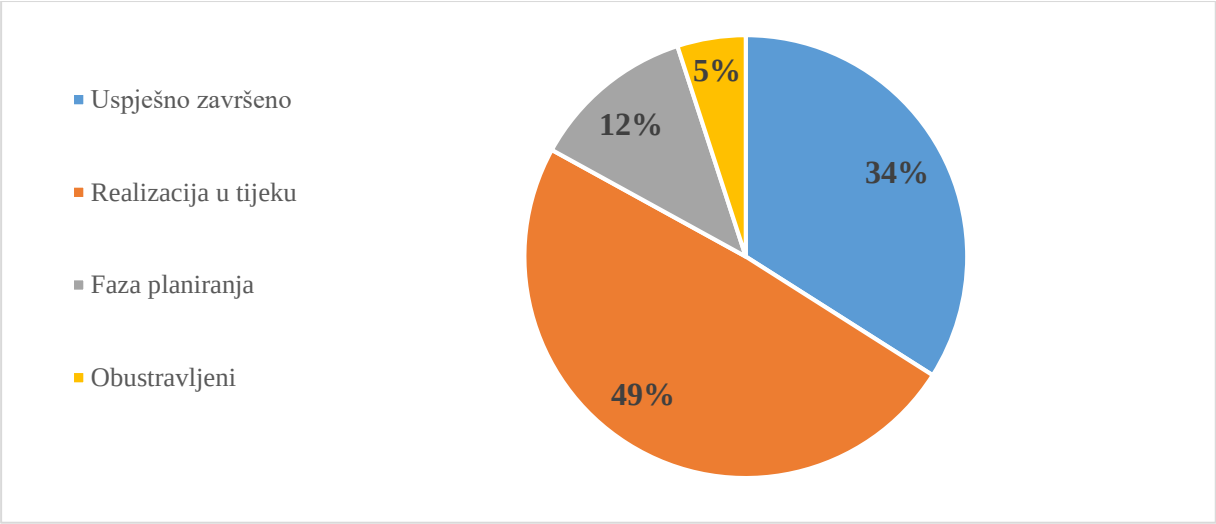

Izvor: Kaganova (2006.), obrada: autor

Samo 28% projekata fokus stavlja na centralizaciju. U privatnom sektoru učinkovita strategija upravljanja nekretninama uključuje centraliziranu financijsku odgovornost za cjelokupni nekretninski portfolio. Glavna prednost centraliziranog upravljanja leži u činjenici da je sustav u cjelini lakše prilagođavati i samim time i upravljati njime. Stoga se iste beneficije pokazuju i u javnom sektoru. (Kaganova, 2006.)

Grafikon 2-5 Fokus projekata upravljanja javnim nekretninama u Njemačkoj

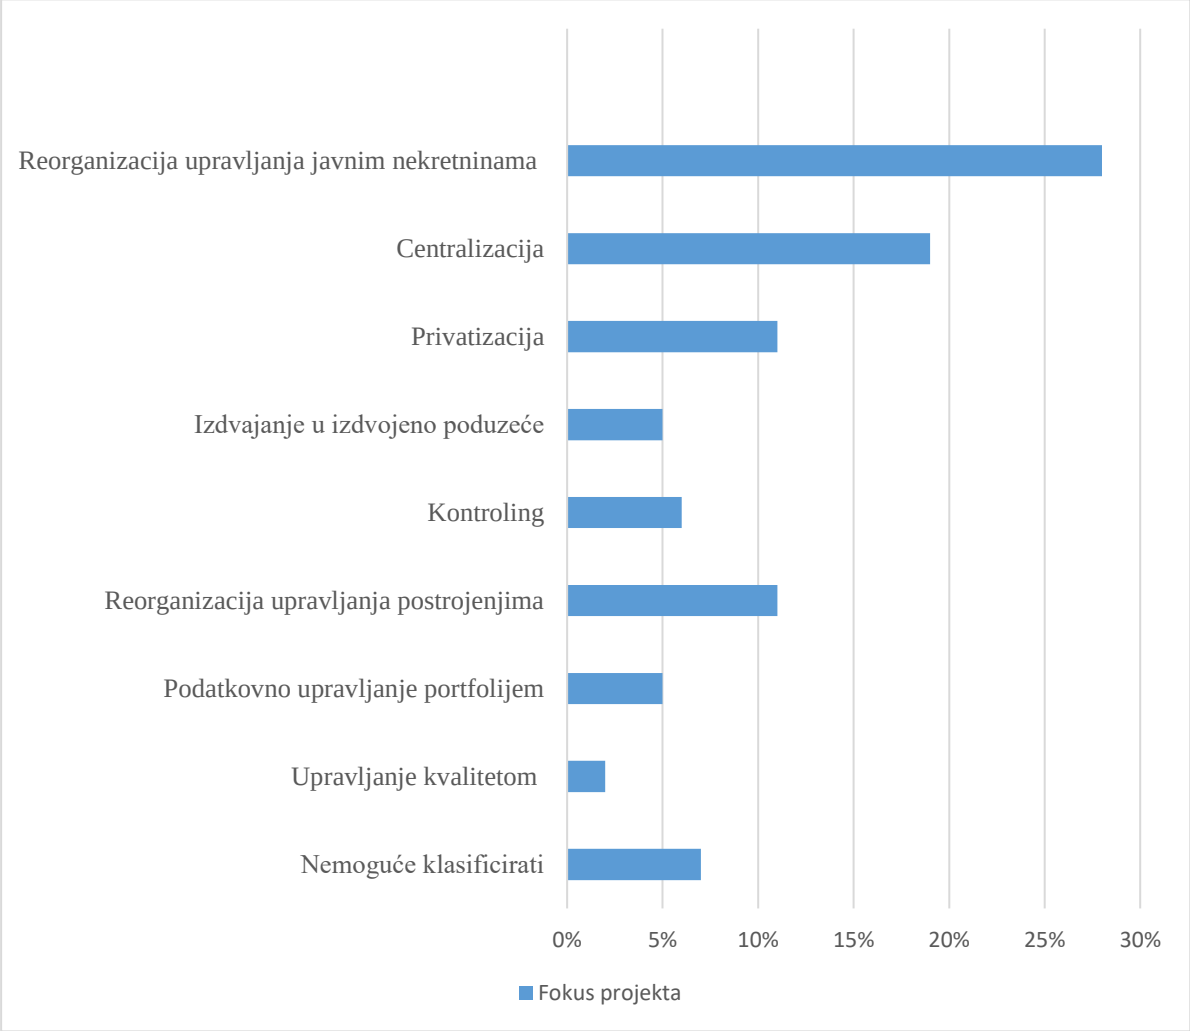

Izvor: Kaganova (2006.), obrada: autor

Kao i u brojnim drugim europskim zemljama, i u Njemačkoj je trend privatizacije javnih usluga, uključujući i funkcije upravljanja nekretninama. Upitani o očekivanim budućim učincima potencijalne privatizacije stvarnih državnih aktivnosti, većina ispitanih lokalnih vlasti predviđa pozitivne i neutralne učinke.

Grafikon 2-6 Očekivani učinci privatizacije usluga javnih nekretnina u Njemačkoj

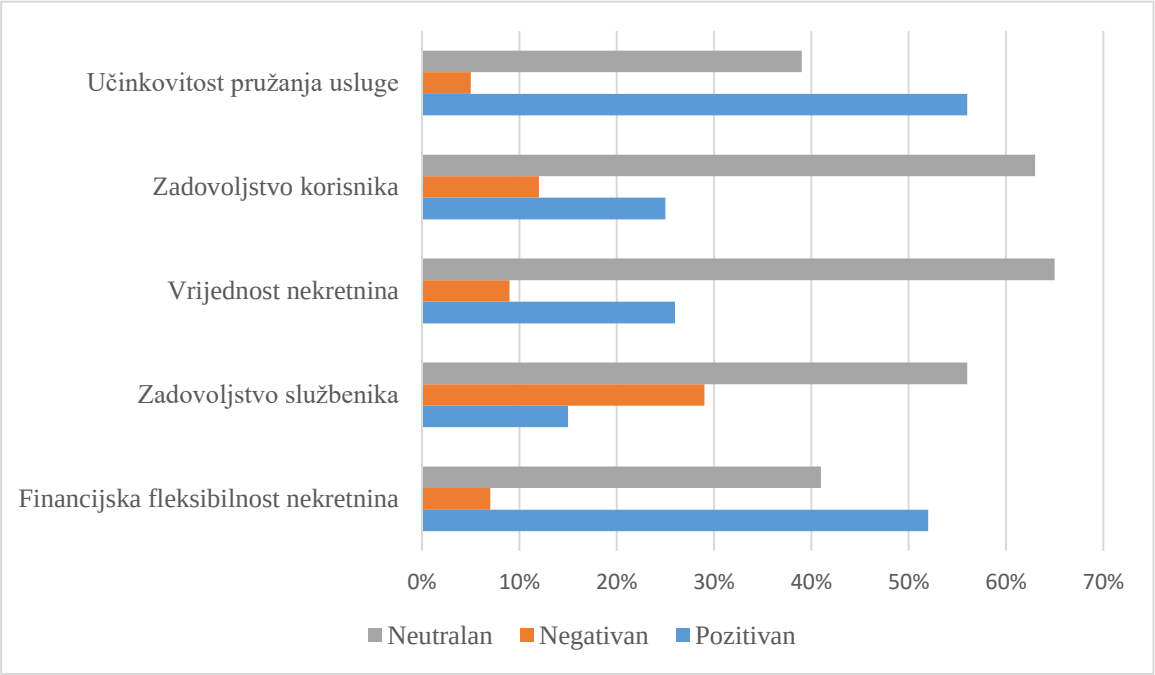

Izvor: Kaganova (2006.), obrada: autor

Kao što grafikon iznad pokazuje, očekuje se da privatizacija ima pozitivan učinak na učinkovitost pružanja usluge, te se očekuje povećana financijska fleksibilnost u upravljanju nekretninama. Također, očekuje se da će utjecaj na zadovoljstvo korisnika tih usluga ostati isti, te da neće imati utjecaj na vrijednost nekretnina.

Grafikon 2-7 Intervencije administracije i političara na proces donošenja odluka vezanih za nekretnine u Njemačkoj

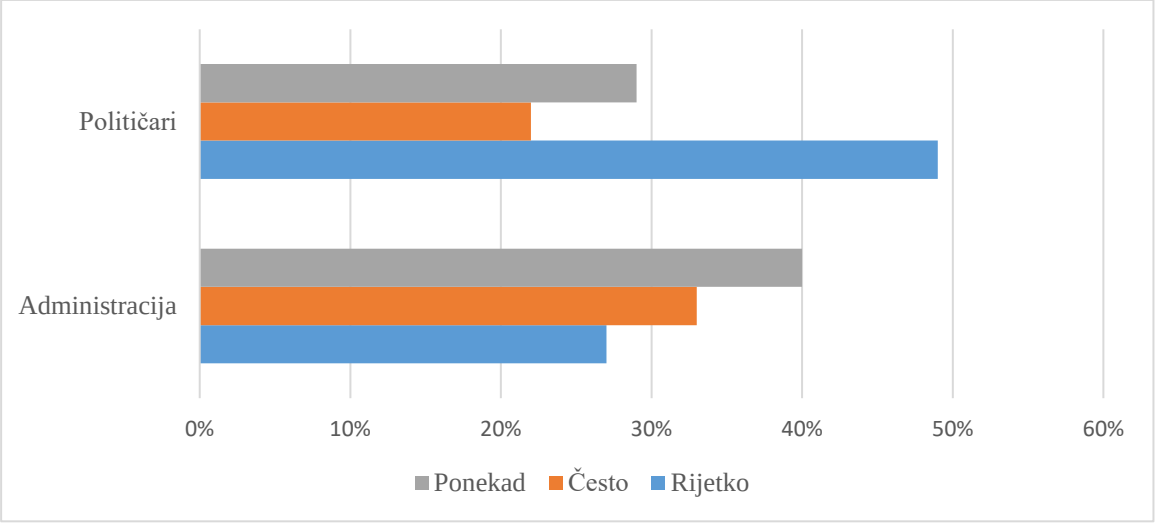

Izvor: Kaganova (2006.), obrada: autor

Lokalne vlasti u Njemačkoj poduzimaju veliku reorganizaciju u upravljanju nekretninama. Ovaj proces ne pokreće samo potreba za poboljšanjem u tom segmentu, već je dio većeg programa modernizacije njemačke javne uprave. Struktura upravljanja javnim nekretninama uglavnom je definirana funkcionalnim linijama, uz jasno razdvajanje proračuna, vlasništva i odgovornosti za operativno izvršenje.

Do sada je samo mali dio vlasti provodio nekretninski kontroling ili uveo IT sustav. Političari još uvijek dominiraju procesom donošenja odluka o nekretninama u Njemačkoj, često na nezadovoljstvo mnogih u administraciji koji smatraju da imaju premalo samostalnosti u svakodnevnom obavljanju svog posla. No postoje i pozitivni aspekti. Većina lokalnih vlasti prepoznaje potrebu za promjenama i inicirala je ili planira inicirati projekte s ciljem poboljšanja učinkovitosti u upravljanju nekretninama u svom vlasništvu.

- **Francuska**

Država je vlasnik najvećeg broja nekretnina u Francuskoj, čiji nekretninski portfolio sadrži između 120 i 150 milijuna kvadratnih metara. Približno, polovica od te brojke su poslovni i uredski prostori, a ostatak su skladišni i arhivski prostori, te otprilike 300 tisuća stanova i kuća. Gotovo 80% svih nabrojanih prostora zauzimaju vladina ministarstva i ostala tijela javne administracije. Ipak, informacije o strukturi i korištenju državnih nekretnina nisu potpune što otežava državi da shvati stvarni potpuni ekonomski potencijal i stvarnu vrijednost svojih nekretnina. (Kaganova, 2006.)

Država još uvijek nema kapacitete za procjenu investicijskog potencijala, vrednovanja, troškova održavanja, operativnih troškova i drugih financijskih čimbenika koji su zajednički upraviteljima portfelja nekretnina u privatnom sektoru. Ta nesposobnost naglašava potrebu za jačanjem i većim rasponom alata za upravljanje i tehnikama kako bi se pomoglo u donošenju odluka poput: iznajmiti ili posjedovati, zadržavanje ili prodaja, obnova ili održavanje – što je sve dio složenog procesa racionalizacije imovine.

Ipak, Francuska se kreće u smjeru pristupa i metodologija upravljanja karakterističnim privatnom sektoru kao dio svoje predanosti procesu reforme koji će ispuniti svoju obvezu poboljšanja javnih usluga i zaštite interesa u javnom vlasništvu. (Agence France Press, 2003.; Kaganova)

Nekoliko javnih tijela organizira upravljanje javnom imovinom i ima specifične nadležnosti vezane uz nekretnine. Njihove glavne uloge su:

- Kupnja – svaka razina vlasti ima legalno pravo stjecati nekretnine. Kupnja se može financirati direktno iz budžeta tijela koje stječe nekretninu ili iz budžeta nekog drugog administrativnog tijela.
- Leasing – svaka razina vlasti ima legalno pravo sklapati ugovore o leasingu nekretnina koje ima u vlasništvu. Zadaća izabranih čelnika je nadzirati pravne uvjete, cijenu i ostale elemente.
- Izgradnja novih nekretnina – svaka razina vlasti može graditi nove nekretnine ili renovirati postojeće. Često više razina ulazi u zajedničke projekte. Npr. izgradnju srednje škole financira regija uz sufinanciranje države.
- Arhitektura i dizajn novih građevina – samo arhitekti s diplomama državnih sveučilišta mogu se prijavljivati na idejne natječaje za konstrukciju zgrada s javnom namjenom.
- Održavanje, sigurnost i ostali poslovi održavanja – svaka razina teritorijalne vlasti ima obavezu održavati nekretnine u svojem vlasništvu te se brinuti pažnjom dobrog gospodara.
- Prodaja – sve razine teritorijalne vlasti u Francuskoj mogu prodavati nekretnine u svom vlasništvu prema točno propisanim uvjetima.
- Konzervacija povijesno značajnih građevina i spomenika kulture – svaka razina vlasti dužna je zaštititi i posebnom pažnjom čuvati arhitektonski, povijesno i kulturno značajne objekte koje posjeduje. Izrađen je vrlo detaljan administrativni i pravni okvir koji konkretno definira odgovornosti i zaduženja različitih tijela državnih i lokalnih vlasti koja su u održavanju, zaštiti i obnovi dužna blisko surađivati s udruženjem arhitekata, arheologa i stručnjacima za umjetnost i povijest. (Kaganova, 2006.)

Francuska je prepoznala značaj dualnosti uloga koje igra kada su nekretnine u pitanju. S jedne strane igra ulogu vlasnika, a s druge strane korisnika velikog broja nekretnina. To je osobito važno za vođenje evidencije imovine koja je temelj učinkovitog upravljanja. Ta evidencija u Francuskoj se naziva *Tableau General des Proprietes de l'Etat (TGPE).* Ipak, informacije iz ove evidencije koriste se isključivo u pravne i fiskalne svrhe jer sustav ne omogućuje precizne informacije poput veličine zemljišta, uporabe, zauzetosti i stanja nekretnine tako da TGPE nije

prilagođen za uporabu kao podloga za upravljanje nekretninama. Sugestije za poboljšanje i modernizaciju sustava su:

- uključiti u sustav nove informacije o pravnom statusu, zauzetosti, planiranim aktivnostima buduće izgradnje i slično
- precizirati razliku između korisnog i nekorisnog prostora, odrediti točne kriterije te ih uvesti u sustav kako bi mogao sam automatizirano rangirati nekretnine
- pojednostaviti način unošenja podataka
- kreiranje jedinstvenog identifikacijskog broja za svaku zgradu koji će biti referentan neovisno o tome koji se poslovi obavljaju vezano uz tu nekretninu i koje tijelo javne administracije ih obavlja.

Također, u tijeku je digitalizacija TPGE sustava, te će nakon završetka taj sustav uključivati detaljne informacije o:

- posjedovanju nekretnina u četiri kategorije: tehnička, pravna, administrativna i ugovorna
- registar projekata u programu obnove
- zapise o izgradnji, održavanju i poboljšanjima nekretnina s mogućnošću praćenja napretka tih poslova
- registar novih projekata
- tehničke informacije o upravljanju nekretninama i potrošnji energije
- grafičke prikaze, slike i ostale medijske sadržaje
- standarde održavanja i mogućnost praćenja programa održavanja
- evaluaciju performansi upravljanja svih tijela uključenih u sustav upravljanja nekretninama (Kaganova, 2006.)

Glavni cilj ovog projekta modernizacije u upravljanju nekretninama je omogućiti svim nadležnim tijelima da u svakom trenutku znaju vrijednost i status uporabe svih svojih nekretnina.

- **Estonija**

U svojoj službenoj državnoj strategiji za nekretnine, objavljenoj 2007. godine, estonska vlada

postavlja jasne smjernice za upravljanje vladinom imovinom sljedećih godina (Riigi 2007, Kask 2014.). Sažeti koncept države za strategiju upravljanjem nekretninama je prebaciti cijeli portfolio državnih nekretnina na bilancu tvrtke za nekretnine u državnom vlasništvu Riigi Kinnisvara AS (engl. *State Real Estate Ltd*., RKAS). Izrada i uvođenje cjelovitog popisa nekretnina bio je jedan od glavnih koraka koje je poduzela estonska vlada kako bi započela reformu u upravljanju nekretninama javnog sektora. Planirano polazište estonske vlade je početi reformu nekretnina najprije s razine opće države i dalje korak po korak spuštati na lokalnu razinu, sve dok se ne uključi cijeli javni sektor.

Nakon prijenosa RKAS je vlasnik i upravitelj skupa nekretnina za posebne namjene i organizator skupa nekretnina općih namjena za raspolaganje privatnom sektoru. Glavna strategija je prodati cijeli skup zgrada opće namjene privatnim investitorima i prebaciti sve zgrade posebne namjene (osim onih za koje to nije moguće) pod upravu RKAS-a. Točna neto površina nekretnina koje će se prodavati nije utvrđena, ali prema navodima u ekspertizi Ministarstva financija u 2010. godini iznosila je oko 524 tisuće četvornih metara (Kask, 2014.). Već sada, ali i u budućnosti, RKAS igra važnu ulogu u estonskoj reformi nekretnina u javnom vlasništvu. RKAS je tvrtka čije dionice 100% pripadaju Republici Estoniji.

Tvrtka je osnovana 2001. od strane estonske vlade s ciljem razvoja upravljanja nekretninama i pomoći institucijama estonske vlade kako bi nekretninama upravljali koordinirano na centraliziran i učinkovitiji način. Iznos običnih dionica iznosi 166,7 milijuna eura (u 2013.), a nositelj portfelja dionica je Ministarstvo financija Estonije. Od 2011. godine tvrtka je investirala u nekretnine u javnom sektoru oko 65 milijuna eura godišnje. Kao javna institucionalna jedinica, sva ulaganja izvršena putem RKAS-a imaju izravni fiskalni utjecaj na državni proračun. Država je obvezala RKAS da mora zaraditi najmanje 7% povrata na kapital (ROE) godišnje. Kao što pokazuje tablica niže, broj nepokretne imovine i zgrada u bilanci RKAS-a postupno je rasla tijekom godina. Konačni cilj vlade u Estoniji je sve državne nekretnine u vlasništvo i upravljanje RKAS-om. (Kask, 2014.)

Tablica 2-2 Promjene u imovini tvrtke RKAS 2007. – 2013.

Godina	Broj nekretnina	Površina nekretnina (m^2)	Broj zgrada	Neto površina zgrada (m^2)
2007.	139	3 373 080	166	424 700
2008.	166	3 650 330	195	428 846
2009.	182	3 948 608	237	422 029
2010.	300	5 882 169	406	450 555
2011.	372	4 878 484	545	565 726
2012.	722	12 209 893	1 051	896 791
2013.	706	14 673 661	1 061	969 804

Izvor: Kask (2014.)

Broj državnih zgrada u bilanci RKAS-a postupno raste zbog provedbe državne strategije upravljanja nekretninama. Do sada, većina državnih tijela od ukupno jedanaest ministarstava prenijela su i vlasništvo i upravljanje njihovim nekretninama na RKAS. Prvi su bili Ministarstvo financija i Ministarstvo obrazovanja. S druge strane, u slučaju Ministarstva obrane još uvijek postoje mnogi problemi koje treba riješiti s obzirom na značaj državne obrane, te neke nekretnine neće nikada biti predane RKAS-u i ostat će u vlasništvu Ministarstva obrane. Početkom 2013. godine u Estoniji je zabilježeno da se nekretninama u javnom sektoru bavi oko 800 službenika. (Kask, 2014.)

- **Novi Zeland**

Promatrajući primjer Novog Zelanda, može se zaključiti kako on predstavlja jednu od rijetkih reformi javnog sektora s izrazito visokim stupnjem dovršenosti. Upravljanje imovinom, pa i nekretninama također je područje gdje možemo mnogo naučiti od ove države. Reforma upravljanja nekretninama povećala je transparentnost i odgovornost u nekretninskim transakcijama i smanjila ekonomsku neučinkovitost povezanu s time.

Trenutni pravni i institucionalni okvir u Novom Zelandu rezultat je kombinacije povijesnih faktora i radikalnog restrukturiranja ekonomije između 1984. i 1994. godine. Do tada je Novi Zeland imao jednu od najzatvorenijih i najreguliranijih ekonomija svijeta. Stoga je u tom desetogodišnjem periodu vlada implementirala svoj program reformi donoseći niz važnih zakona koji su, među ostalim, doveli i do:

- privatizacije ili korporizacije velike većine državnih trgovačkih odjela (engl. *Trading depatments)*

- restrukturiranja ministarstva i agencija, razjašnjavanja njihovih odgovornosti i uloga koje obavljaju
- širokog uvođenje koncepta upravljanja učinkom (engl. *Performance managemant)* i izvještavanja između različitih dijelova uprave
- promjena u konceptu financiranja različitih vladinih odjela od financiranja inputa do kupnje konkretnih outputa
- uvođenja sustava kapitalnih doprinosa (engl. *Capital contributions)* kroz mehanizam izdvajanja (engl. *Appropriation mechanism)*
- uvođenja GAAP-a (engl. Generally Accepted Accounting Pratice).

Državna riznica Novog Zelanda reformirala je financijsko upravljanje u javnom sektoru novim uputama s naglaskom na dugotrajnoj imovini i troškovima koje bi trebale dovesti do povećanja odgovornosti proračunskih korisnika i učinkovitijeg upravljanja s ciljem podizanja poslovnih rezultata javnog menadžmenta. Reforma uključuje i niz financijskih propisa koji reduciraju fiskalnu potrošnju kroz učinkovitu kontrolu javnih rashoda i podižu zahtjeve za odgovornim upravljanjem državnim resursima.

Općenito, vlada je bila dužna pridržavati se propisa koji reguliraju privatni sektor u korištenju, razvoju i upravljanju imovinskim posjedima te upravljati svojim udjelima na isti način kao i svaka privatna korporacija ili pojedinac. Istovremeno, vladine agencije bile su predmet novih mjera odgovornosti s uvođenjem izlaznih sporazuma (engl. *Output purchasing agreements)* na svim razinama vlasti. Trenutni izlazni sporazum koji glavni rukovoditelji odjela i druge vladine agencije potpisuju sa svojim ministrima definiraju ishode koje će agencije proizvesti u narednoj godini i pokazatelje koji će se koristiti za mjerenje uspjeha. Uvođenje mjerenja uspješnosti izravno je utjecalo na upravljanje državnom imovinom. Posebne mjere izvedbe povezane s korištenjem zemljišta definirane su kao outputi u ugovorima i uključene u neke godišnje prognoze odjela i izvještaje na kraju godine, posebno one s velikim zemljišnim posjedima gdje se zemljište smatra značajnom aktivnošću ili one sa zakonskim odgovornostima za upravljanje zemljištem.

Unutar javnog sektora, restrukturiranje ministarstava i prelazak na kupnju definiranih rezultata putem sporazuma odražavali su naglasak na cijelom sustavu na razlikovanju vladinih vlasničkih i kupovnih interesa. Učinak iz perspektive vlasništva obično uključuje postizanje željenog

povrata ulaganja. S druge strane, kupac je zainteresiran je li usluga isporučena kako je dogovoreno ili očekivano. (Simpkins, 1998.; Kaganova, 2006.)

Te su reforme utjecale na način na koji je država provodila sve svoje funkcije, uključujući upravljanje imovinom. Načini upravljanja državnom imovinom odražavaju ovu razliku na svim razinama. Primjerice, ministarstvo obrazovanja osigurava financiranje škola. U okviru operacija bespovratna sredstva su komponenta koja obuhvaća financiranje cikličkog održavanja školskih zgrada. Odgovornost škole u pogledu svojih zgrada utvrđena je u dva dokumenta: dokument o popunjenosti imovine, koji određuje relativne odgovornosti između škole i ministarstva i 10-godišnji plan nekretnina koji priprema škola, a u kojem se navodi kako će škola održavati svoje zgrade. Na taj način ministarstvo osigurava usluge upravljanja i održavanja javnih škola.

Formalno, sva zemlja na Novom Zelandu pripada državi, personificirana od strane Kraljevske krune, dok se privatnim strankama dodjeljuje "besplatno jednostavno pravo zakupa" (engl. *Free simple tenure).* U stvarnosti, nekretnine su jasno podijeljene između privatnog i državnog vlasništva. Praćenje nepokretne imovine sada je potpunije sa stajališta računovodstva i inventara, jer se svaki dio državne nekretnine, uključujući i neizgrađeno zemljište, mora pojaviti na financijskom izvješću izvještajnog subjekta Krune.
Povijesno gledano, Kruna je bila izuzeta od pridržavanja niza zakona i propisa. To je dovelo do situacije u kojoj bi se često prije završavali radovi na izgradnji bez formalne suglasnosti jer su objekti bili u vlasništvu Krune i smješteni na zemlji u vlasništvu Krune.
Danas, trenutna zakonska regulativa obvezuje Krunu u području zakonske usklađenosti. Iako postoje poteškoće u građanskim predmetima, filozofija je da je Kruna odgovorna za svoje postupke i mora preuzeti odgovornost kako bi osigurala da ispunjava zahtjeve vlastitog zakonodavstva koje se primjenjuju na bilo koji drugi entitet. (Kaganova, 2006.)

Kao i u drugim zemljama, odgovornost za državnu imovinu podijeljena je na mnoga tijela središnje vlasti. Stjecanje, držanje i pravo raspolaganja za određeni dio nekretnine mogu biti odgovornost jednog tijela ili podijeljeno između nekoliko tijela. Tijela državne uprave dijele se u tri glavne kategorije, od kojih sve mogu imati državnu nekretninu na svojim bilancama i određena prava i odgovornosti za upravljanje imovinom: odjele (engl. *Departments),* pravne entitete Krune (engl. *Crown entities)* i poduzeća u državnom vlasništvu (engl. State-owned enterprises).

Slika 2.1 Tijela i uloge u upravljanju državnom imovinom Novog Zelanda

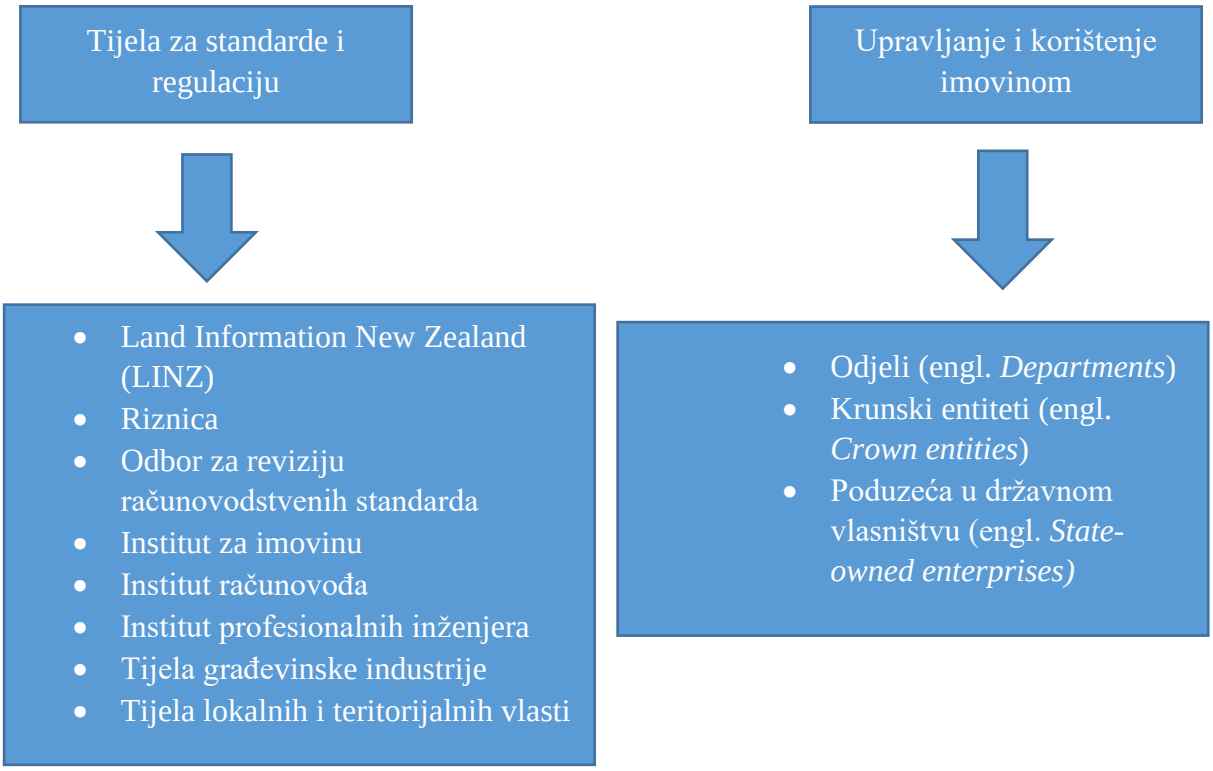

Izvor: Kaganova, 2006.

NZ razlikuje krunu i odjele. Kruna je zapravo "Njezino Veličanstvo Kraljica s pravom na Novi Zeland" (engl. " Her Majesty the Queen in right of New Zealand") i uključuje sva ministarstva Krune i sve odjele, ali ne uključuje Ured Parlamenta, entitet Krune ili državno poduzeće. Odjeli se stoga pravno ne mogu razlikovati od Krune, ali se smatraju zasebnima za potrebe upravljanja. Primjerice, samo bilanca koju odjel kontrolira i koristi u proizvodnji svojih outputa uključena je u bilancu odjela. Prema tome, nekretnine mogu biti u vlasništvu odjela i pojavljivati se u bilanci odjela ili biti upravljane odjelima u ime Krune i pojavljivati se na bilanci Krune.

Odjeli imaju pravo koristiti bilo koji raspoloživi obrtni kapital i sve prihode od otuđenja sredstva za kupnju ili razvoj kapitalne imovine, pod uvjetom da se neto imovina odjela ne povećava kao izravna posljedica. Ako je nekretnina prodana, svaki višak sredstava nad knjiženom knjigovodstvenom vrijednošću vraća se u riznicu. Međutim, transakcije nabave i otuđenja nekretnina moraju slijediti standarde koje je postavila LINZ, državno tijelo koje ima sveukupnu odgovornost za upravljanje zemljištem u vlasništvu Krune. Svaka promjena šalje se u LINZ-u na odobrenje.

Krunski entitet (engl. *crown entity)* je kategorija koja obuhvaća širok raspon organizacija od lokalnih školskih odbora do okružnih zdravstvenih odbora i niza regulatornih i drugih tijela za pružanje usluga. Za razliku od odjela, krunski entiteti su pravno odvojeni od Krune. Kruna ima kontrolni interes, ali ne odgovara za obaveze koje nastaju.

NZ koristi sustav koji kombinira godišnje proračune i dugoročne financijske okvire, slično kao što je slučaj u EU. Financijsko upravljanje isprepliće se s operativnim upravljanjem kroz sporazume o izvedbi i rezultatima koji uspostavljaju ciljeve i prate uspješnost. Središnje državno tijelo izdaje smjernice o očekivanim učincima.

2.2.2. Model logističke podrške upravljanju nekretninama gradova

Prvi i osnovni problem upravljanja nekretninama općenito leži u nepostojanju cjelovitih evidencija o nekretninama u vlasništvu i posjedu gradova. Glavna zadaća te evidencije je biti jedinstvena, cjelovita i dostupna ovlaštenim korisnicima u gradovima. Također, postoji potreba kvalitetnoga i učinkovitoga sustava upravljanja nekretninama te lakoj i brzoj dostupnosti podataka i informacija potrebnih za učinkovito odlučivanje. Kada se ispune ovi navedeni preduvjeti, nastaju pretpostavke za minimizaciju troškova poslovanja što je glavni cilj predmetnog modela kojeg je razvila i predlaže Irena Guszak. Razvijen je koncept čiji su korisnici JLP(R)S u RH, neovisno o tome koriste li se podrškom informacijskih tehnologija ili ne. Također se naglašava njegova korisnost i za područnu (regionalnu) samoupravu, tijela državne uprave, organizacije i ustanove u vlasništvu JLP(R)S-a.

Logističko-informacijski sustav uključe podatke o objektima (nekretninama), izvore ulaznih podataka, odredišta izlaznih podataka, postupke obrade, tokove i spremište podataka o osnovnim objektima u sustavu upravljanja nekretninama u vlasništvu JLP(R)S, odnosno nekretninama. Temeljne vrste podataka (atributa) nekretnina uključuju fizičke, podatke o korištenju i fizičke podatke, a u sustav se unose na dva načina, nakon početnog punjenja.

Prvi je ručni unos operatera zaduženog za punjenje baze podataka atributima objekata, a drugi prihvat podataka iz drugih dijelova poslovno-informacijskog sustava JLP(R)S. Sustav je modeliran prema načelu unošenja svakog podatka samo jedanput nakon čega je dostupan u svim relevantnim dijelovima informacijskog sustava.

Tako se stvara baza informacija dostupna svim korisnicima koji aktivno sudjeluju u upravljanju nekretninama u vlasništvu JLP(R)S-a i donose odluke u vezi s njima. Svrha je informacijskog sustava pružanje informacija korisnicima koji donose odluke, a aktualan je trend primjene koncepta za donošenje učinkovitih odluka naziva *Business Intelligence* (skraćeno BI) koji isporučuje točne i korisne informacije na temelju kojih je moguće donositi pravovremene i učinkovite odluke.

Korisnici podataka i izvješća sustava upravljanja nekretninama uključuju izravne, organizacijsku jedinicu za upravljanje nekretninama, i neizravne kao što su odjel za financije, proračun i računovodstvo, zatim poglavarstvo, vijeće, odbori, javnost, državne institucije i dr. Izvješća se pripremaju za tri razine odlučivanja: operativnu, taktički i stratešku i podržavaju procese upravljanja nekretninama (kupnja i prodaja nekretnina, davanje u najam, zakup ili koncesiju, gradnja i održavanje nekretnina). Cilj je sustava omogućiti unos podatka nastalih kroz poslovne procese u bazu podataka te obradu i prikaz kroz relevantna izvješća. (Guszak, 2008.)

Slika 2.2 Model logističke podrške upravljanju nekretninama u vlasništvu gradova

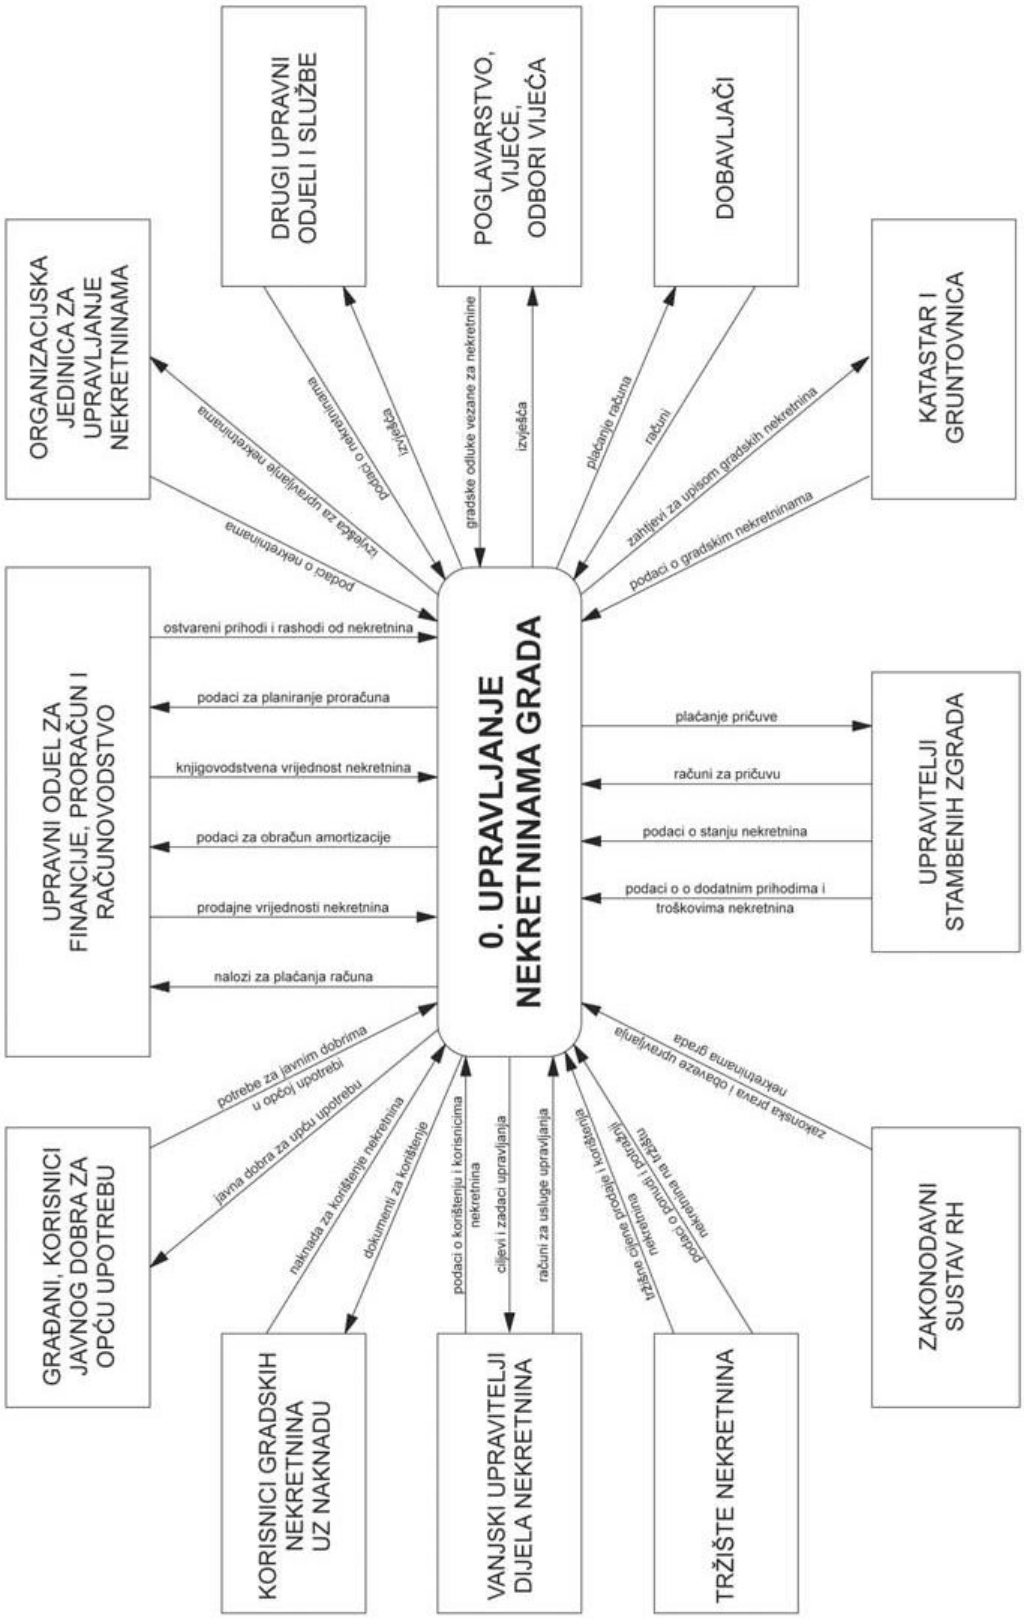

Izvor: Guszak (2008.)

U kontekstu ove disertacije zanimljiv je nalaz iz istraživanja (Guszak, 2008.) o ključnim problemima u upravljanju nekretninama gdje svi ispitanici kao ključni problem navode nepotpune popise imovine. Također, gotovo svi ispitanici (92%) navode i lošu organizaciju upravljanja imovinom.

Pogodnosti stečene projektom uključuju promjenu svijesti o značaju nekretnina, uređivanje evidencija i trajno ostvarivanje inventure i utvrđivanja vrijednosti nekretnina u vlasništvu gradova, kao i osvješćenje u vezi s potrebom za informatičkom protočnosti i dostupnosti podatka u sklopu strateškom načinu upravljanja nekretninama. (Guszak, 2008.)

Grafikon 2-8 Ključni problemi u upravljanju nekretninama

Izvor: Guszak (2008.)

2.2.3. Modeli upravljanja nekretninama u javnom sektoru

Razlike u upravljanju mogu se općenito izraziti kroz konstrukciju PREAM modela (engl. Public sector real estate asset management), koji su zapravo generalizacija skupa kvalitativno opisanih obilježja upravljanja imovinom. Najvažnije značajke ili parametri koji opisuju PREAM modele

općenito su: vlasništvo, upravljanje i financiranje; tj. opis načina kako su nekretnine u javnom sektoru, odnosno vlasništvu, upravljane i financirane. (Kask, 2014.)

Jedno od načela je uspostavljanje tržišne učinkovitosti i načela dobrog upravljanja u aktivnostima jedinica vlasti. Analiziranjem literature i najboljih praksi upravljanja nekretninama javnog sektora, jasno se može identificirati neriješeni problem, a to je stupanj odvojenosti funkcije vlasništva od upravljanja. Stupanj razdvajanja varira od vlade do vlade, ali općenito se koriste dva zajednička i izrazito različita modela (Kaganova, 2006):

1) Prvi model pretpostavlja da vlada zadržava izravno vlasništvo nad imovinom
(ili barem najveći dio "paketa prava" koji je povezan s vlasništvom) i delegira funkcije upravljanja imovinom drugom entitetu, obično ugovorom.
2) Drugi model pretpostavlja da se imovina države prepusti vlasnički drugom entitetu (u zapadnim zemljama ovaj entitet je često korporacija); u takvom slučaju, korporacija, a ne vlada, posjeduje imovinu, dok vlada posjeduje ili kontrolira korporaciju.

Oba modela izazivaju niz pitanja, uglavnom o upravljanju tim subjektima koji upravljaju imovinom i odnosu vlasti s njima. Osnova za PREAM modele preuzeta je iz iskustva najbolje prakse iz Njemačke. Nijemci razlikuju tri vrste organizacijskih modela za sektor upravljanja javnim nekretninama:

1. model vlasništva
2. model najmodavca i najmoprimca
3. model upravljanja. (Schulte i Ecke 2006, Kask 2014.)

U modelu vlasništva korisnik je odgovoran za sve ključne funkcije povezane s tom nekretninom, kao što je održavanje, upravljanje objektima i praćenje troškova. S obzirom na fiksni proračun, korisnik je također odgovoran za ugovaranje različitih intervencija s vanjskim pružateljima usluga (održavanje, čišćenje, popravci i sl.).

Modelom najmodavca i najmoprimca definirane su dvije različite uloge:

1. najmoprimac, organizacija koja koristi imovinu, i
2. najmodavac kao vlasnik nekretnine.

Uloga najmoprimca obično pripada nekom pružatelju usluga (npr. školi koja pruža uslugu obrazovanja), dok je uloga najmodavca vezana uz vlasništvo predmetne nekretnine.

Najmoprimac ima dvije glavne odgovornosti:

1) minimiziranje svih troškova vezanih uz upravljanje imovinom:
2) plaćanje ugovorenih naknada stanodavcu.

Najmodavac zauzvrat:

- upravlja i održava imovinu prema ugovoru o najmu;
- koordinira s pružateljima usluga trećih strana;
- vodi brigu o održavanju imovine;
- ispunjava zahtjeve iz vladinih politika i strategija.

Treći model, model upravljanja, je kombinacija prethodna dva modela s dodatkom upravljačke funkcije. Osim najmodavca i najmoprimca, dodatni upravljački subjekt odgovoran je za upravljanje imovinom i aktivnosti održavanja. Riječ je o vrlo fleksibilnom modelu koji je u pravilu definiran pojedinačnim specifičnim ugovorima o pružanju usluga s najmoprimcem ili najmodavcem koji određuju zadatke tog upravljačkog subjekta.

Faktori za PREAM mjerenja uzeti su iz različitih teorija koje se odnose na temu. Potrebno je primijeniti odgovarajuću metodologija za primjenu tih mjerenja kako bi se analizirala financijska izvedivost (engl. *feasibility*) nekretnina u javnom sektoru. S obzirom na temu aktualnog istraživanja, autor tumači pitanja što se tiče PREAM-a kao zasebne izazove koji se mogu riješiti koristeći pristup dugoročne analize projekta (engl. *long-term project-based analysis approach*).

Stoga se raspravlja o metodama koje ocjenjuju dugoročne projekte javnog sektora, kako u smislu jedinstvene nekretnine tako i na razini agregiranog skupa nekretnina.

2.3. Pretpostavka za upravljanje nekretninama gradova

Nakon što smo definirali pojam nekretnina potrebno je definirati pojmove procjene i vrijednosti.

2.3.1. Procjene vrijednosti nekretnina

U prethodnim poglavljima definiran je pojam nekretnina, te je na početku ovoga potrebno definirati pojmove procjene i vrijednosti. Procijeniti u kontekstu ovog rada znači odrediti vrijednost odnosno utvrditi cijenu. U ekonomskoj teoriji vrijednosti postupak procjene se opisuje kao mjerenje. Dakle, riječ je o mjerenju odnosno uspoređivanju usporedivih mjernih objekata uz uporabu standardiziranih mjernih jedinica. Definiranje vrijednosti je pokušaj valorizacije i objedinjavanja koje različite pretpostavke, poput fizičkog stanja nekretnine, pravnog interesa, situacije na tržištu, u zadanom trenutku imaju utjecaj na cijenu koju nekretnina može ostvariti. Upravo iz tog razloga je IVSC (*engl.* International Valuation Standards Council– Međunarodno vijeće za normizaciju vrednovanja) postavio standard koji omogućava zajedničku definiciju tržišne vrijednosti. Tržišna vrijednost predstavlja vrijednost koju nekretnina može ostvariti ako je ponuđena na prodaju na otvorenom tržištu na dan izrade procjene. Kako bi odredili tržišnu vrijednost, procjenitelj prvo mora procijeniti upotrebu iz koje predmetna nekretnina ostvaruje najbolju uporabu (engl. *Best use)* ili njenu najvjerojatniju upotrebu, što može biti trenutna funkcija te nekretnine ili neka od alternativnih. To se određuje iz dokaza pribavljenih na tržištu. Pojam najbolja uporaba (engl. Best use) često je korišten u literaturi i određen je optimalnim korištenjem koje je pravno dopušteno unutar financijskih okvira s maksimalnim mogućim iskorištenjem koje rezultira najvećim prihodom (IVSC 2007).

Vrednovanje nekretnina je središnje pitanje i načelo neovisno o tome tko im je vlasnik. Nekretnine su faktori proizvodnje i njihova vrijednost ovisi o njihovoj upotrebi. Procjena vrijednosti je utvrđivanje iznosa novca koje nekretnina može uprihoditi svom vlasniku na dan izrade procjene. Procjene se vrše zbog različitih svrha poput:

- prodaje i kupnje, pomoć kupcu u određivanju ponude, pomoć prodavatelju u određivanju prihvatljive prodajne cijene
- izračun poreza, određivanje porezne osnovice za porez na promet nekretnina
- ugovaranja i isplate osiguranja
- revidiranje knjigovodstvene vrijednosti dugotrajne imovine u bilanci poslovnih subjekata
- kreditni kolateral za osiguranje povrata kredita
- određivanje osnovice za nadoknade štete u sudskim procesima
- nasljeđivanja

- investiranja i financiranja.

Vrednovanje nekretnina je nužno kako bi nam omogućilo kvantifikaciju koristi i obaveza koje proizlaze iz vlasništva nad nekretninama. Valuacije su potrebne i služe različitim dionicima tržišta nekretnina poput agencija za promet nekretninama, procjeniteljima, poreznicima, rentijerima, brokerima, vlasnicima, investitorima, istraživačima i analitičarima, konzultantima i drugima. Stoga, procjena vrijednosti nekretnina ima središnju ulogu i za gradove koji su predmet istraživanja ovog rada.

Pfnur (2005.) raspravlja kako stvarna stanja nekretnina – nepokretnost, heterogenost i ograničena tržišna sposobnost – svaku nekretninu čine jedinstvenom što je samo po sebi u proturječju s pretpostavkom usporedivosti teorije vrijednosti što se prevladava smanjivanjem zahtjeva za usporedivost toliko da se mogu koristiti uobičajene mjerne jedinice za procjenu čime se smanjuje preciznost rezultata. Uobičajena mjerna jedinica za procjenu vrijednosti stvari, pa tako i nekretnina, je novac.

Procjena odnosno određivanje vrijednosti nekretnine složen je postupak koji zapravo kvantitativno vrednuje kvalitativna svojstva predmetne nekretnine. Potrebno je naglasiti i objasniti razliku između tržišne vrijednosti i cijene. Cijena koja se postigne između prodavatelja i kupca može, ali često nije jednaka tržišnoj vrijednosti nekretnine, što znači da je potrebno sagledati sve činjenice vezane uz konkretnu kupoprodaju – uvjeti, rok(ovi), povezanost sudionika ili drugi relevantni čimbenici koji utječu na donošenje odluka u kupoprodajnom procesu. Prema IVSC-u (*engl.* International Valuation Standards Council), TEGoVA-i (Europska organizacija procjeniteljskih udruga – *engl*. The European Group of Valuers' Associations) i direktivi 2006/48/EC Europske komisije, definicija tržišne vrijednosti glasi: „Tržišna vrijednost je novčani iznos za koji nekretnina može biti razmijenjena na određeni datum, u transakciji između zainteresiranog kupca i zainteresiranog prodavatelja, pod objektivnim uvjetima, nakon odgovarajućeg marketinga, pri čemu obje strane imaju odgovarajuća znanja i informacije, te djeluju bez prinude." (IVSC 2007, TEGoVA 2009, EC 2006).

Definicija tržišne vrijednosti prema USPAP-u, odnosno normi profesionalne procjeniteljske prakse (engl. Uniform Standards of Professional Appraisal Practice): „Najprihvatljivija cijena koju bi trebala imati nekretnina na konkurentnom i otvorenom tržištu, a prema postavljenim uvjetima tržišne prodaje". U slučaju pojedinačne procjene vrijednosti nekretnina u proces

procjene uključen je procjenitelj te obilazak nekretnine na licu mjesta kako bi se definirale mogućnosti korištenja predmetne nekretnine koje moraju biti usklađene s urbanističkim planovima, ali i realno stanje na terenu odnosno stupanj uređenja i dostupnost područja u odnosu na urbanističku infrastrukturu. Kako bi izradio procjenu, procjenitelj koristi svoje iskustvo i znanje čime određuje utjecaj različitih faktora na procijenjenu vrijednost nekretnine. Na procijenjenu vrijednost utječu društveni, ekonomski, okolišni, državni i politički faktori koji vrijede na dan izrade procjene.

Kada raspravljamo o vrijednosti nekretnine, zapravo raspravljamo o sadašnjoj vrijednosti budućih tokova novca, odnosno odgovaramo na pitanje kakve prihode gospodarenje nekretninom može ostvariti. Postoje različite vrste vrijednosti koje se procjenjuju, poput:

- tržišna vrijednost
- gotovinska vrijednost
- likvidna vrijednost
- prodajna vrijednost
- otkupna vrijednost
- zamjenska vrijednost
- knjigovodstvena vrijednost
- vrijednost osiguranja itd.

U praksi se najčešće koriste sljedeće metode za pojedinačnu procjenu vrijednosti nekretnine:

- troškovna (engl. *Cost approach)*
- dohodovna (engl. *Income capitalization approach)*
- tržišna usporedba (engl. *Sales Comparison approach).*

Procjena vrijednosti nekretnina u Republici Hrvatskoj regulirana je Zakonom o procjeni vrijednosti nekretnina[12]. Procjenu vrše ovlaštene osobe koje su stalni sudski vještaci i stalni sudski procjenitelji. U Republici Hrvatskoj najčešće se koristi poredbena metoda jer je pogodna za izradu procjena u uvjetima slabo razvijenog tržišta nekretnina što je slučaj u Hrvatskoj. Također, domaće tržište karakterizira nedostatak podataka o postignutim cijenama sličnih nekretnina što je isto tako čimbenik koji utječe na izbor ove metode. Osnovna pretpostavka

[12] NN 78/215

metode je da nitko ne želi platiti nekretninu više od cijene njene izgradnje. Dakle, temelj za procjenu troškovnom metodom su potrebni troškovi za izgradnju. Tržišna vrijednost određuje se zbrojem sadašnjih troškova izgradnje reprodukcijske građevine, tržišne vrijednosti zemljišta i dodatnih troškova koji uključuju infrastrukturne, projektne i ostale troškove.

Razlika između knjigovodstvene i tržišne vrijednosti nekretnine daje jasan signal upravlja li se učinkovito svojom imovinom, odnosno u konkretnom slučaju portfeljem nekretnina.

Usporedba tržišne i knjigovodstvene vrijednosti pojedine nekretnine ukazuje na nesrazmjer tih veličina, a odnos je u prosjeku 5:1. Takve informacije upućuju na to da je vrijednost nekretnina u vlasništvu hrvatskih lokalnih jedinica pet puta veća od one evidentirane, a toj se vrijednosti mora dodati vrijednost svih nekretnina koje tek valja uvrstiti u knjigovodstvene evidencije gradova i općina. (Bertović, 2004.; Guszak, 2008.).

Također, postoji i često se koristi masovno vrednovanje (engl. *mass valuation*). Riječ je o postupku koji na osnovi objektivnih pokazatelja vrednuje veliki broj nekretnina statističkom metodologijom. Upravljanje velikim i modernim sustavima, a pogotovo u urbanim područjima, zahtijeva i masovnu procjenu odnosno masovno vrednovanje nekretnina. Masovno vrednovanje se izrađuju za veća područja, a posebno su značajna u gradovima odnosno u urbaniziranim područjima. Podaci i informacije koje izvodimo iz takvih sustava koriste se za uvođenje sustava pravednijeg oporezivanja vlasnika nekretnina ili posjeda na nekretninama, učinkovitije upravljanje tržištem nekretnina i gospodarenju prostorom u širem smislu.

Osnovna razlika između masovnog vrednovanja i pojedinačnog vrednovanja nekretnina leži u tome da se prilikom pojedinačnog vrednovanja sagledavaju, analiziraju i vrednuju specifičnosti pojedine nekretnine, dok se u masovnom vrednovanju nekretnina traže sličnosti. To znači da masovno vrednovanje zahtijeva zadovoljavajući broj međusobno usporedivih podataka za potrebe vrednovanja nekretnina za koje se radi. Također, druga značajna razlika odnosi se na kriterij subjektivnosti. Vrijednost nekretnine koje su procijenjene pojedinačnom metodom od strane procjenitelja uvelike ovise o njegovom iskustvu i znanju.

U pojedinačnim procjenama nemoguće je isključiti subjektivan dojam procjenitelja, pa moguće i vlastiti interes koji može nastati zbog povezanosti s naručiteljem procjene. S druge stane, masovnim vrednovanjima je teško ili nemoguće istaknuti određene specifičnosti pojedine nekretnine koja nije zajednička širem skupu nekretnina na nekom području.

Zbog kompleksnog postupka i širokog izbora metoda masovno vrednovanje nekretnina je zapravo multidisciplinaran postupak koji je praćen razvojem računalnih tehnologija kao podrška (engl. *Computer-Assisted Mass Appraisal – CAMA).* Dakle, njime se bave stručnjaci iz različitih područja: ekonomije, građevine, statistike, geodezije, informatike.

Kao što je ranije spomenuto, postoji širok izbor različitih metoda:

- višestruka regresijska analiza (engl. *Multiple Regression Analysis – MRA)*
- umjetna neuronska mreža (engl. *Artificial Neural Network – ANN*)
- GIS metoda (engl. *Geographic Information System – GIS)*
- metoda ekspertnih sustava (engl. *Rule based Expert systems)*
- kombinacija modela.

U praksi se najčešće koristi višestruka regresijska analiza, umjetna neuronska mreža i GIS metoda. Sve navedene metode imaju svoje prednosti i nedostatke koje su navedene u tablici:

U ožujku 2019. je vlada Republike Hrvatske donijela Uredbu o masovnoj procjeni vrijednosti nekretnina (NN 28/19) kojom se prvi put uređuju pitanja masovne procjene vrijednosti nekretnina i propisuje metoda, model te nužni podaci, postupci korištenja i vrednovanja podatka za masovnu procjenu vrijednosti nekretnina u Republici Hrvatskoj. Primjenjivat će se za masovnu procjenu vrijednosti nekretnina i neizgrađenih i izgrađenih zemljišta, zgrada i njihovih posebnih dijelova koji se koriste za stanovanje ili najam, kao i poslovne zgrade i prostore.

Tablica 2-3 Usporedba najčešće korištenih metoda masovne procjene

Metoda	Prednosti	Nedostaci
Višestruka regresijska analiza	Statistička osnova i široka prihvaćenost	Prepoznaje samo linearne ovisnosti i potreban je velik broj poznatih podataka
Umjetna neuronska mreža	Pronalaženje linearnih i nelinearnih uzoraka i trendova, adaptivna	Netransparentnost izračuna, nestabilan model, potreban veliki broj poznatih podataka
GIS metoda	Transparentnost izračuna, nije potreban veliki broj poznatih podataka	Ovisnost o subjektivnom dojmu pri postavljanju težina čimbenika

Izvor: Kask (2014.)

Zakon o procjeni vrijednosti nekretnina bavi se isključivo tržišnom vrijednošću nekretnina koju procjenjuje koristeći tri metode i sedam postupaka koji propisuju način prikupljanja podataka na temelju propisane metodologije, kao i procjenu i daljnje korištenje.

Informacijski sustav tržišta nekretnina eNekretnine omogućava ovlaštenim procjeniteljima i posrednicima u prometu nekretninama lak pristup podacima na temelju kojim mogu kvalitetno raditi. Takva baza podataka važna je zbog osiguranja transparentnosti tržišta nekretnina, a uključuje podatke o transakcijama i vrstama nekretnina koje su bile predmet transakcije (stan, kuća, poslovni prostor, poljoprivredno, građevinsko, šumsko zemljište, itd.)

Cilj je uredbe upotpunjavanje nužnih podataka kao što su obilježja vrste nekretnine, podaci o ostvarenom prometu nekretninama, lokacija, ploština, predvidivi ostatak održivog vijeka korištenja i infrastruktura na temelju kojih se može razraditi model za masovnu procjenu vrijednosti nekretnina.

Uredba također propisuje način identificiranja nekretnina te korištenje tržišne vrijednosti nekretnine kao osnovicu za vrednovanje čime se prilikom masovne procijene vrijednosti nekretnina dobivaju vrijednosti prilagođene tržišnom stanju. Za procjenu se koristi metoda višestruke regresijske analize, a modeli za masovnu procjenu vrijednosti nekretnina utemeljeni su na troškovnoj, poredbenoj i prihodovnoj vrijednosti nekretnina. Također su propisani nužni podaci, postupci korištenja i vrednovanje podataka za masovnu procjenu vrijednosti nekretnina u Republici Hrvatskoj.

2.3.2. Upravljanje imovinom gradova iz bilančne perspektive

U ovom se poglavlju proučava upravljanje nekretninama iz bilančne perspektive.

Kao osnova financijskoj izvještavanja, bilanca je temelj financijskoj modeliranja i računovodstva i od velikog je značaja za upravljanje. Bilanca je sustavi pregled imovine, kapitala i obveza na određen datum (obično 31.12.), a kao dvostrani računovodstveni iskaz mora imati uravnoteženu lijevu i desnu stranu. Računovodstvenim jezikom, sastoji se od aktive (imovine) i pasive (izvori imovine) i prikazuje ukupnu aktivu i pasivu što omogućava financijsku analizu, kao i analizu zaduženosti, profitabilnosti, likvidnosti i aktivnosti. Bilanca prikazuje omjer imovine i obveza, a pregledom neto imovine u bilancama možemo izmjeriti „zdravstveno stanje“ financija.

George Peterson u svojem poglavlju knjige Managing Government Property Assets sugerira kako se neto imovina u bilancama lokalnih zajednica može povezati s kapitalom lokalnog stanovništva. Uprava koja gradi imovinu kako bi pružala uslugu građanima, bez velikih zaduživanja zapravo kreira javno dobro u ime građana – poreznih obveznika. S druge strane, uprava koja gomila javni dug i dopušta da imovina probada zapravo erodira javno dobro. (Kaganova, 2006.) Ipak, ova analogija ima određene limite s obzirom na to da je glavni cilj javne uprave ipak pružanje usluga i stvaranje ekonomskih prilika za stanovništvo, a akumuliranje bogatstva je sekundarni cilj. No povećanja i smanjenja neto imovine kroz vrijeme koristan je indikator učinkovitosti javne uprave.

Bilanca osigurava vrijednu stratešku perspektivu upravljanja imovinom od strane lokalnih jedinica vlasti. Iz slučaja Kine možemo izvući lekcije. Ako javni stambeni prostor čini više od polovice vrijednosti imovine na bilancama općina, jasno je da je prioritet razviti strategiju upravljanja javnim stambenim prostorom, koja uzima u obzir i tržišnu vrijednost nekretnina i osnovnu svrhu takvih projekata – stambenu pomoć. Ishod ove strateške procjene može biti privatizacija stambenog fonda za privatizaciju stambene imovine, učinkovitije upravljanje imovinom stambenog fonda koji ostaje javan ili rekonfiguracija sastava stambenih jedinica u vlasništvu općina prodajom nekretnina visoke vrijednosti i ponovnim ulaganjem u pristupačne stambene objekte prikladnije namijenjenim korisnicima.

U mnogim dijelovima svijeta nekretnine u javnom vlasništvu ekonomski su potpuno podcijenjene i "zaključane" u birokratiziranim institucijama koje tu vrijednost ne prepoznaju često zato jer su imune na tržišne utjecaje. Prioritet bi trebao biti utvrđivanje zemljišnih posjeda u javnom vlasništvu, procjena tržišnih vrijednosti najvažnijih zemljišnih parcela i projektiranje metode za "oslobađanje" tih vrijednosti putem selektivne prodaje zemljišta i preseljenja javnih objekata koji mogu jednako dobro funkcionirati na drugim mjestima, a oslobađaju vrijedna zemljišta za prodaju ili *leasing*.

Uloga poticaja i propisa je relativna. Propisi mogu zahtijevati da općine izrade bilancu ili usvoje određene računovodstvene konvencije za vrednovanje imovine i reorganizaciju novih vrsta obveza. Sami računovodstveni propisi vjerojatno neće potaknuti vladine agencije da poduzmu nove oblike djelovanja. To je uloga ekonomskih i financijskih poticaja. U slučaju Kine, općine su se počele ponašati drugačije kada su uspjele zadržati financijske koristi od zakupa zemljišta. Slična slika pojavljuje se u gotovo svakoj instituciji. Vladine agencije više vole provoditi tržišno orijentirane reforme u upravljanju nekretninskom imovinom kada su u mogućnosti zadržati,

unutar svojih vlastitih proračuna, značajan dio ušteda ili "dobiti" koju te reforme generiraju. (Kaganova, 2006.)

2.4. Učinkovitost upravljanja gradovima i važnost upravljanja nekretninama za uspješnost gradova

Promatrajući funkcioniranje gradova važno je pratiti njihovo učinkovitost kroz politike lokalnog ekonomskog razvoja. Učinkovitost upravljanja nekretninama potrebno je strateški definirati s ciljem gospodarskog razvoja gradova u budućnosti.

2.4.1. Politike lokalnog ekonomskog razvoja i razvojni potencijali gradova

U zadnjih dvadesetak godina počeo se koristiti pojam lokalni ekonomski razvoj (LER), prvo u SAD-u gdje se radilo na aktivnijoj ulozi lokalne zajednice, modela odozdo (engl. *bottom-up*), a danas se načela LER-a koriste kao instrument regionalne politike i u europskim zemljama (Čavrak, 2008.) U stručnoj literaturi nalazimo više definicija LER-a, ali svima je zajedničko definiranje LER-a kao kontinuiranog planskog procesa u kojem uz lokalnu vlast sudjeluju poduzetnici, NGO i građani u svrhu poticanja ekonomskog rasta i razvoja te poboljšanje kvalitete života stanovništva.

Lokalni ekonomski razvoj možemo definirati i kao proces kroz koji lokalne vlasti surađujući s partnerima iz javnog, poslovnog i nevladinog sektora stvaraju uvjete za ekonomski rast i nova radna mjesta. Takav proces potiče poduzetničku klimu i stvara okruženje u kojem se razvija viša kvaliteta života za stanovništvo lokalne zajednice.

U sklopu lokalnog ekonomskog razvoja iskorištavaju se lokalni resursi za zadržavanje postojećih i stvaranje novih radnih mjesta te ojačavanje i promoviranje poslovnih aktivnosti. Zato je nužna koordinacija javnog, poslovnog i neprofitnog sektora i zajedničko razvijanje strategije za lokalni ekonomski rast i povećanje zaposlenosti.

Rezultat je povećanje konkurentnosti i održivi razvoj (World Bank, 2001.) Pregledom svih definicija vidimo da se lokalnim zajednicama u zadatak daje razvijanje vlastitog gospodarskog i društvenog razvoja što znači da suvremeni pristup lokalnom razvoju ključnu ulogu daje lokalnoj samoupravi, a ne središnjoj vlasti. Jedan od preduvjeta takvog razvojnoj modela (odozdo) zasigurno je ekonomska globalizacija koja je umanjila potrebu za nacionalnim politikama.

U 21. stoljeću tradicionalan pristup ekonomskom razvoju (odozgo) postaje neučinkovit, a gradovi i općine sve podložnije kretanjima globalnog svjetskog tržišta. Odgovor razvijenih zemalja bio je LER, model koje lokalnu vlast čini ključnim nositeljem ekonomskih odluka na lokalnoj razini, novi instrument razvoja regija, gradova i općina.

Jedinice lokalne samouprave Republike Hrvatske nisu prije 1990. godine i prelaska na tržišno gospodarstvo mogle funkcionirati sukladno načelima LER-a iz sljedećih razloga:

1) Ekonomski planovi koji su uključivali lokalan razvoj donosili su se na državnoj razini (u bivšoj Jugoslaviji), odnosno u centrima političke moći, gdje se odlučivalo što će se u lokalnim zajednicama graditi i kako će se to financirati. Lokalne zajednice nisu sudjelovale u procesu odlučivanja i primarno su ispunjavale ulogu pružanja administrativnih usluga.

2) Zakoni nisu omogućavali postojanje privatnog poslovanja (s izuzetkom malog obrtništva) što znači da nije postojao privatni sektor koji bi se mogao uključiti u aktivnosti lokalne samouporave.

3) Građani su na ekonomsku dobrobit svoje lokalne zajednice mogli utjecati samo kroz političko djelovanje unutar jedine dozvoljene političke stranke, dok bilo kakve druge aktivnosti građana nisu bile institucionalizirane. S prelaskom na tržišno gospodarstvo u Hrvatskoj postaje očita važnost suvremenih načela upravljanja lokalnim razvojem prema modelu razvoja „odozdo“, a znanost i struka počinju se baviti pitanjima lokalnog ekonomskog razvoja za čime su uslijedile i konkretne aktivnosti pojedinih institucija ili pojedinaca u sklopu gradova i općina (Bogović, 2009.)

2.4.2. Značaj strateškog upravljanja nekretninama za gospodarski razvoj gradova

Nekretnine kojima upravljaju i koje su u posjedu lokalnih vlasti predstavljaju veliki potencijal za gospodarski razvoj tog područja i prosperitet lokalnog stanovništva. Ova tvrdnja jednako vrijedi u Republici Hrvatskoj kao i u drugim zemljama.

Upravljanje možemo definirati kao cjelovito djelovanje neke organizacije, pojedinca ili grupe pojedinaca usmjerenih na proaktivno, učinkovito i rapidno djelovanje s ciljem ostvarivanja unaprijed definiranih željenih ishoda.

Upravljanje također možemo definirati kao koordinirano vođenje i usmjeravanje procesa s ciljem ostvarenja zadanog cilja. Upravo tako upravljanje definira Pusić: *„Upravljanje je kontinuirana djelatnost povezivanja više ljudi u akciji na obavljanju nekih društvenih poslova. Djelatnost upravljanja teče u okviru sistema pravila kojima su, s jedne strane, utvrđeni njezini postupci, a s druge strane, određeni interesi kojima treba da služi.“* (Pusić, 1973.; Seršić, 2013.)

Upravljanje imovinom u vlasništvu jedinica lokalne samouprave možemo podijeliti na sljedeće segmente: evidentiranje imovine, održavanje, unaprjeđenje, briga o zaštiti, briga o upotrebi i briga o ekonomskoj dobiti za proračun od imovine. Osnovni preduvjet upravljanju imovini upravo je segment evidentiranja imovine koji mora na precizan i točan način uvesti imovinu u poslovne knjige i pridružiti joj početnu vrijednost (Seršić, 2013.).

Organizacije javnog sektora u Europi teže održivom razvitku i u skladu s time formiraju pojedinačne strategije, što uključuje i strategiju upravljanja i raspolaganja nekretninama. Održivi razvita definiramo kao razvoj koji posredno i neposredno donosi gospodarsku dobit sadašnjem stanovništvu uz brigu o zaštiti okoliša i javnih dobara kako bi u njima mogle uživati i buduće generacije.

Definicija održivog razvitka iz Strategije održivog razvitka Republike Hrvatske (NN, 30/09.) glasi: „Održivi razvitak je razvitak koji zadovoljava potrebe današnjice, a pritom ne ugrožava potrebe budućih generacija. Održivi razvitak ostvaruje ravnotežu između zahtjeva za unapređivanjem kakvoće života (ekonomska sastavnica), za ostvarivanjem socijalne dobrobiti i mira za sve (socijalna sastavnica) te zahtjeva za očuvanjem sastavnica okoliša kao prirodnog dobra o kojima ovise i sadašnja i buduće generacije. Poštivanje načela demokracije, ravnopravnosti spolova, socijalne pravde i solidarnosti, zakonitosti, poštivanje prava čovjeka te očuvanje prirodnih dobara, kulturne baštine i čovjekova okoliša pridonose očuvanju Zemlje za održavanje života u svoj svojoj raznolikosti. Na taj se način održivi razvitak ostvaruje kroz dinamično gospodarstvo s punom zaposlenošću, ekonomsku, socijalnu i teritorijalnu koheziju, visok stupanj obrazovanosti građana, visok stupanj zaštite zdravlja i očuvanje okoliša.“

Strategija upravljanja i raspolaganja nekretninama treba biti uvrštena u strategiju jedinice lokalne samouprave s obzirom na to da su nekretnine lokalne samouprave strateški važan resurs. Ako su strategija jedinice lokalne samouprave i strategija upravljanja i raspolaganja

nekretninama neusklađene, to uzrokuje neučinkovito raspolaganje nekretninama. Bitno je razumjeti da je strategija dinamična kategorija i treba joj duže razdoblje da se rafinira jer je baza nekretnina složena i opsežna, te i nakon proteka i do nekoliko godina donesena strategija treba biti redovito kontrolirana da bi mogla učinkovito odgovarati i prilagođavati se unutarnjim i vanjskim promjenama.

U jednostavnim uvjetima svrha strategije upravljanja nekretninama je osigurati (RICS, 2008.):

- platformu za strogo i strukturirano razmišljanje prema naprijed
- osnovu za korporativne i konzultativne strategije razvoja
- izričito opis smjera organizacije kojim želi ići sa svojom bazom nekretnina
- jasna izjava organizacije za komuniciranje
- temelj za buduće donošenje odluka.

Za strategiju upravljanja i raspolaganja nekretninama drži se važnim uspostaviti i politiku upravljanja i raspolaganja nekretninama koja utječe na sve odluke u lokalnoj samoupravi i odražava izbor lokalne samouprave prema svom vlasništvu, i jednako tako određuje način ponašanja unutar organizacije – svima je jasno na koji se način trebaju ponašati. Strategijom upravljanja i raspolaganja nekretninama grad određuje svoje dugoročne ciljeve i smjernice upravljanja i raspolaganja nekretninama u svom vlasništvu. Svaka jedinica lokalne samouprave treba pronaći optimalno rješenje koje će dugoročno očuvati nekretnine, te s tim u skladu i interese lokalne samouprave. Svaka strategija upravljanja nekretninama trebala bi se temeljiti na načelima zakonitosti, svrsishodnosti i ekonomičnosti, odnosno ulagati u nekretnine koje su bitne za ostvarivanje interesa lokalne samouprave, te gospodarskih i socijalnih interesa zajednice, pažnjom dobrog gospodara.

Također, vrlo je značajan i plan upravljanja i raspolaganja nekretninama. Plan upravljanja i raspolaganja nekretninama preduvjet je učinkovitog upravljanja. Tu je činjenicu prepoznao i zakonodavac, te je takav plan zakonska obaveza. Plan kao operativno-upravljački dokument provodi se na svim razinama lokalne samouprave, pa i u gradovima.

Ako se na strateško planiranje gleda kao na interdisciplinarni napor usmjeren realiziranju fundamentalnih odluka i djelovanja koja oblikuju i usmjeravaju organizaciju, te se time određuje što organizacija radi, zašto to radi i način na koji to radi, možemo zaključiti da je

strateško planiranje definitivno jedan od ključnih elemenata u oblikovanju načina rada, razmišljanja i ponašanja unutar gradskih uprava.

Urbanizacija i gospodarski razvoj neodvojivo su povezani pri čemu bi uloga središnje vlasti u planiranju i provedbi razvoja trebala biti obrnuto proporcionalna samostanom djelovanju gradova, u svrhu poboljšanja razvoja kako pojedinačnih gradova, tako i čitave nacije. Može se reći da je nacionalni ekonomski razvoj posljedica i sinergija razvojnih uspjeha na lokalnoj razini pri čemu snagu najslabije karike određuje ukupna nacionalna snaga. Ovaj ideal nije lako provesti u praksi, ali ujednačavanje regionalnog razvoja ključni je cilj svih nacionalnih zajednica bez obzira na postojeću ekonomsku razvijenost. (Bogović, 2014.)

2.5. Utjecaj upravljanja nekretninama na lokalni ekonomski razvoj i na uspješnost financijskog poslovanja gradova

Kako su nekretnine sastavni dio cjelokupne ekonomije, promjene u vrijednosti nekretnina ili obujmu transakcija na tržištu imovine može uzrokovati ozbiljne štete na gotovo sve sektore gospodarstva. Na primjer, smanjenje prodaje nekretnina može na kraju dovesti do pada cijena nekretnina, što opet znači i smanjenje u vrijednosti kolaterala hipoteka, što u konačnici može ozbiljno ugroziti zdravlje cjelokupnog gospodarstva. To se jasno vidjelo tijekom posljednje velike recesije u razdoblju od 2008. do 2010. godine. Općenito, tržište nekretnina može se karakterizirati heterogenošću vlasničkih interesa, potrebno je relativno dugo vrijeme transakcije, kao i prisutnost aglomeracije podtržišta (engl. sub-markets).

Aktualni snažni trendovi urbanizacije i globalizacije zahtijevaju kvalitetne razvojne politike, osobito gospodarske, a očituju se u konstantnom povećanju relativnog broja urbanog stanovništva odnosno stanovništva koje živi i/ili radi u gradovima, te dominacije urbane ekonomije u kreiranju nacionalnog dohotka. Uloga nacionalnih ekonomija u globalizaciji slabi, jačaju nadnacionalne organizacije, ali istovremeno se sve veći naglasak stavlja na razvoj lokalnih zajednica. Stoga je uloga urbanih cjelina, a pogotovo gradova za gospodarski razvoj od iznimnog značaja. Uzmemo li u obzir značaj upravljanja nekretninama u upravljanju gradovima opisan u prethodnim poglavljima, razvidan je značaj upravljanja nekretninama na lokalni ekonomski razvoj, te samim time i na financijsko poslovanje gradova.

Prema prije iznesenim tvrdnjama, uloga i značaj gradova osnažen je procesima urbanizacije, globalizacije i decentralizacije, no istovremeno se pred lidere gradskih vlasti te pred gradske vlasti u cjelini stavljaju sve veće razine odgovornosti u upravljanju kvalitetom života najvećeg broja ljudi.

Stoga je važan i utjecaj liderskih sposobnosti lokalnog političkog vodstva kojeg nije nimalo jednostavno opisati, definirati i kvantificirati. No svakako se može neizravno mjeriti učinkom koji stvaraju u odnosu na ukupnu količinu raspoloživih materijalnih resursa što su u ovom slučaju nekretnine u vlasništvu jedinica lokalne vlasti kojima upravljaju. Definitivno je jedna od najvažnijih zadaća lidera definiranje i provedba vizije i strategije koju nižerangirani službenici nadopunjuju akcijskim planovima s jasnim, konkretnim, dostižnim i realističnim, mjerljivim, vremenski određenim ciljevima. Dužnost političkih lidera je kreiranje promjene kroz razvojne politike i strateško upravljanje. Ipak, razina racionalnosti često je oprečna s političkim procesima koji često dominiraju u lokalnoj samoupravi.
Kada je riječ o upravljanju gradovima i nekretninama u vlasništvu gradova, najviše pozicionirani politički menadžeri su gradonačelnici. Oni imaju presudan utjecaj na kreiranje strateških ciljeva, motivaciju suradnika i nižerangiranih službenika u provedbi projekata kojima se dostižu zadani ciljevi presudni za postizanje kontinuiranog napretka i izvrsnosti. Česta je pojava da se zbog utjecaja i vođenja dobrih i modernih lidera na pozicijama gradonačelnika identificiraju i gradovi koji i sami postaju lideri u svom okruženju ili šire, te čiji primjeri poticajno djeluju i na druge lokalne vlasti (engl. *benchmarking*).

Zadatak je vođe nadahnuti suradnike koji rade na realizaciji strategije razvoja i "pokrenuti ljude" u okruženju koje je samo po sebi inertno i nesklono promjenama, a hoće li vođa dobiti potporu ili naići na otpor ovisi o sljedećem:

- Zaposlenici mogu zbog iskustva s prijašnjim neuspjelim pokušajima uvođenja promjena pružati znatan otpor.
- Neadekvatno organizirane procedure rada i složeni birokratski postupci s krutim pravila često su faktor u otporu promjenama.
- Vođe zbog prijašnjih radnih iskustava i (ne)znanja mogu postupati pristrano i sukladno tome griješiti u organizaciji poslova.

- Potencijalni sukobi s centrima političke moći mogu rezultirati ometanjem, uskraćivanjem informacija i osobnim sukobima, kao i nesuradnjom među upravnim tijelima grada i opstrukcije aktivnosti drugih političkih opcija.
- Vremenska ograničenja i politički pragmatizam u praksi često prioritet daju ostvarenju kratkoročnih političkih ciljeva umjesto dugoročnoj strategiji i viziji. (Bogović, 2014.)

3. UPRAVLJANJE NEKRETNINAMA U VLASNIŠTVU GRADOVA U REPUBLICI HRVATSKOJ

Upravljanje nekretninama u vlasništvu gradova u Republici Hrvatskoj definirano je kroz institucionalni okvir i kroz praksu dosadašnjeg upravljanja. Kvaliteta i uspješnost upravljanja nekretninama ovisi o nekoliko čimbenika od kojih se može istaknuti stručno znanje i iskustvo djelatnika gradova kao jedan od važnijih alata.

3.1. Institucionalni okvir upravljanja nekretninama u Republici Hrvatskoj

Imovinu jedinica lokalne, odnosno područne samouprave čine sve pokretne i nepokretne stvari te imovinska prava koja im pripadaju, proizlazi iz odredbi čl. 67. Zakona o lokalnoj i područnoj (regionalnoj) samoupravi (NN 33/01, 60/01, 129/05, 109/07, 125/08, 36/09, 36/09, 150/11, 144/12, 19/13, 137/15 i 123/17; u daljnjem tekstu: ZLP(R)S). Međutim, takva naizgled jednostavna formulacija često otvara puno više pitanja nego što nudi odgovora, a odgovore je potrebno potražiti u odredbama drugih propisa koji izravno ili neizravno uređuju pitanja gradske imovine. S obzirom na činjenicu da pokretne stvari vrlo često ne zauzimaju toliko značajan udio u portfeljima imovine JLP(R)S, fokus šire stručne javnosti i nadležnih tijela na upravljanje i raspolaganje nepokretnom imovinom u vlasništvu Grada je itekako opravdan.

Upravljanje gradskom imovinom možemo definirati kao sintagmu koja objedinjuje niz različitih kompleksnih i multidisciplinarnih aktivnosti u okviru poslovanja jedinice lokalne samouprave, a u prilog takvoj konstataciji svakako ide ocjena Državnog ureda za reviziju (nastavno: DUR) prema kojem svega 32 od ukupno 576 jedinica lokalne i područne samouprave na području Republike Hrvatske učinkovito upravlja i raspolaže nekretninama u svom vlasništvu. Takva ocjena stanja proizlazi iz Izvješća o obavljenoj reviziji učinkovitosti upravljanja i raspolaganje nekretninama jedinica lokalne i područne (regionalne) samouprave Državnog ureda za reviziju objavljenog u ožujku 2016. godine. Budući da je citirano izvješće produkt sažimanja svih pojedinačnih revizijskih izvješća za razdoblje od 2012. do početka 2015. godine, određene formulacije o utvrđenim slabostima u upravljanju imovinom imaju uglavnom univerzalan karakter. Tako se, između ostaloga, navodi kako lokalne jedinice ne ne posjeduju u cijelosti ili djelomično podatke o stvarnom stanju imovine kojom upravljaju i raspolažu, zatim kako nisu ustrojile i ne vode registre imovine, kako nisu utvrdile namjenu

nekretnina kojima upravljaju te kako u poslovnim knjigama nisu evidentirane sve poslovne promjene u vezi s nekretninama. Međutim, da bismo pristupili otklanjanju naprijed navedenih, a nažalost i brojnih drugih utvrđenih slabosti i nepravilnosti, osobito se valja osvrnuti na utvrđenje DUR-a prema kojem lokalne jedinice nisu donijele strategiju upravljanja i raspolaganja nekretninama.

U prilog spomenutoj kompleksnosti i multidisciplinarnosti upravljanju imovinom ističemo činjenicu kako su način vođenja knjigovodstvenih evidencija o imovini lokalnih jedinica te iskazivanje imovine u financijskim izvještajima propisani odredbama Pravilnika o proračunskom računovodstvu i Računskom planu (NN 124/14, 115/15, 87/16 i 3/18) i Pravilnika o financijskom izvještavanju u proračunskom računovodstvu (Narodne novine 3/15, 93/15, 135/15, 2/17, 28/17 i 112/18). Navedeni propisi, odnosno operativni poslovi i zadaci koji se na istima temelje, svakako su u domeni službenika u ustrojstvenim jedinicama nadležnim za poslove računovodstva i financija.

Nadalje, kako bismo mogli postići zakonitu funkcionalnu distinkciju pojedinih portfelja imovine, potrebno je konzultirati odredbe niza različitih propisa u rasponu od temeljnog propisa kojim se uređuje područje lokalne i područne samouprave pa do propisa kojima se uređuju područja Grad i gradova, proračun ili prostorno uređenje. Međutim, kako su navedena upravna područja, odnosno propisi kojima su ista uređena uglavnom usmjereni semantičkom definiranju određenih pojmova te evidentiranju okolnosti o vrijednosti i stanju imovine, može se izvesti zaključak kako je područje raspolaganja i upravljanja imovinom JLP(R)S potrebno podvesti pod izrazito široki obuhvat pojma imovinskopravnih poslova, o čemu će biti više riječi u nastavku.

Zakon o vlasništvu i drugim stvarnim pravima (NN 91/96, 68/98, 137/99, 22/00, 73/00, 129/00, 114/01, 79/06, 141/06, 146/08, 38/09, 153/09, 143/12 i 152/14; u daljnjem tekstu: ZV) jest mjesto u zakonu odlučno za rješavanje nekog pitanja u odnosu na sva pitanja kojima se uređuje pravo vlasništva, ali u smislu ovog dokumenta posebno je važno istaknuti odredbe članka 391. istog zakona koji propisuje prava i uvjete raspolaganja nekretninama u vlasništvu jedinica lokalne samouprave. Tako je u stavku 1. istog članka propisano kako se nekretnine u vlasništvu JLP(R)S mogu otuđiti, odnosno kako se njima može raspolagati samo na osnovu javnog natječaja i uz naknadu utvrđenu po tržišnoj cijeni, ako zakonom nije drugačije određeno, dok su stavcima 2. i 3. propisane iznimke od navedenog pravila. Prva iznimka odnosi se na situacije

u kojima pravo vlasništva na nekretninama u vlasništvu JLP(R)S stječu Republika Hrvatska i druge JLP(R)S, odnosno pravne osobe u njihovom pretežitom vlasništvu, dok se druga iznimka odnosi na raspolaganje zemljištem radi formiranja građevne čestice, i to ne većeg od 20 % površine planirane građevne čestice. U istom smislu valja spomenuti i odredbe članka 176. Zakona o prostornom uređenju (NN 153/13) koji propisuje uvjete pod kojima su JLP(R)S dužne na zahtjev vlasnika prodati dio zemljišta radi formiranja izgrađene, odnosno neizgrađene građevne čestice u skladu s detaljnim planom uređenja.

Stupanjem na snagu Zakona o upravljanju državnom imovinom (NN 52/18) uvode se određene novosti u relativno statičnom normativnom okviru koji uređuje predmetno područje, slijedom čega posebno ukazujemo na odredbe članka 70. istog Zakona. Tako će se u skladu s odredbama citiranog članka u vlasništvo jedinica lokalne i područne samouprave upisati sve nekretnine koje su u zemljišnim knjigama upisane kao vlasništvo Republike Hrvatske i koje su se na dan 1. siječnja 2017. koristile kao škole, domovi zdravlja, bolnice i druge ustanove kojima su osnivači jedinice lokalne i područne (regionalne) samouprave, kao i groblja, mrtvačnice, spomenici, parkovi, trgovi, dječja igrališta, sportsko-rekreacijski objekti, sportska igrališta, društveni domovi, vatrogasni domovi, spomen-domovi, tržnice te javne stube.

Kako se navedene iznimke odnose na prilično ograničene slučajeve raspolaganja nekretninama, mišljenja smo kako je osobito važno istaknuti izrazito ozbiljnu i moguće dalekosežnu posljedicu postupanja protivno odredbama članka 391. ZV-a, a ona se odnosi na ništetnost takvih pravnih poslova. Ukratko, prema odredbama čl. 323. Zakona o obveznim odnosima (NN 35/05, 41/08, 125/11, 78/15; u daljnjem tekstu: ZOO), u slučaju ništetnosti ugovora svaka je ugovorna strana dužna vratiti drugoj strani sve ono što je primila na temelju takva ugovora, uz potencijalnu odgovornost za štetu ugovaratelja koji je kriv za sklapanje ništetnog ugovora. Držimo nužnim istaknuti kako mnogi ništetni poslovi mogu postojati i proizvoditi učinke, ali prava opasnost sklapanju takvih poslova leži u okolnosti kako na ništetnost sud pazi po službenoj dužnosti, na nju se može pozvati svaka zainteresirana osoba, a pravo na isticanje ništetnosti se ne gasi.

Budući da se može zaključiti kako se izrada Strategije upravljanja imovinom odnosi uglavnom na postojeće nekretnine kojima Grada upravlja, u nastavku ćemo predstaviti neke temeljne propise koji uređuju područje raspolaganja nekretninama u najširem smislu. Opći propis obveznog prava, s obzirom na to da u svom općem dijelu sadrži opsežne odredbe kojima se

uređuje područje obveznih odnosa, dok se u posebnom dijelu uređuju ugovorni odnosi, jest naprijed navedeni ZOO. U kontekstu ovog dokumenta ističemo i posebne propise kojima se detaljno razrađuju pojedini instituti raspolaganja nepokretnom imovinom, a to su Zakon o zakupu i kupoprodaji poslovnog prostora (NN 125/11 i 64/15) i Zakon o najmu stanova (NN 91/96, 48/98, 66/98, 22/06 i 68/18). Normativni okvir svakako čine i opći akti JLP(R)S te ZLP(R)S) kojima se, između ostaloga, utvrđuju ovlasti i nadležnosti gradskih tijela glede raspolaganja i upravljanja imovinom. Tek po razvijanju svijesti o složenosti normativnog okvira, odnosno posljedicama eventualnog propuštanja postupanja po istome, pristupa se (ništa manje složenoj) operativnoj izradi i donošenju pojedinačnih akata i isprava kojima se raspolaže imovinom JLP(R)S.

Nadalje, u očekivanju donošenja nove strategije, navodimo kako je na temelju Zakona o upravljanju i raspolaganju imovinom u vlasništvu Republike Hrvatske (NN 94/13 i 18/16) donesena je Strategija upravljanja i raspolaganja imovinom u vlasništvu Republike Hrvatske za razdoblje od 2013. do 2017. godine (NN 76/13) koja u točki 9. sadrži odredbu sljedećeg sadržaja: „U pogledu nekretnina ovom se Strategijom utvrđuju smjernice koje su dužni poštovati svi upravitelji nekretnina u vlasništvu Republike Hrvatske, jedinice lokalne i područne (regionalne) samouprave i ovlaštena tijela za rješavanje prostorne problematike, kada upravljaju nekretninama na podlozi općih propisa.“

Takvu formulaciju, iako možda na prvi pogled upitne kogentnosti, a uz uvažavanje prethodno navedene ocjene DUR-a prema kojem lokalne jedinice nisu donijele strategije upravljanja i raspolaganja nekretninama, možemo shvatiti kao izrazito indikativnu u kontekstu sve užeg fokusa nadležnih tijela na problematiku upravljanja imovine u vlasništvu JLP(R)S. Međutim, iako se uz strateško planiranje vežu prilično apstraktni i univerzalni pojmovi koji se odnose na stavljanje nekretnina u vlasništvu Grada kao važnog resursa gospodarskog razvoja u širu društvenu i gospodarsku funkciju, držimo kako bi pogrešno bilo donositi strateške planove upravljanja imovinom samo u svrhu formalnog zadovoljenja nametnutih obveza. Stoga bi u razdoblju prije, a osobito prilikom izrade strateških planova, valjalo uzeti u obzir velik broj čimbenika koji mogu biti od utjecaja na upravljanje imovinom. Veličina jedinica lokalne samouprave, njihov geografski položaj, eventualna prometna ili strateška važnost, gospodarska razvijenost, turistički potencijali te financijski i kadrovski kapaciteti samo su neki od tih čimbenika koji u velikoj mjeri mogu biti od utjecaja pri planiranju upravljanja i raspolaganja imovinom. Plastičnije rečeno, nije moguće na isti način planirati iskorištavanje potencijala

nekretnina u razvijenim turističkim središtima u odnosu na manje gradove i općine kontinentalne Hrvatske.

U kontekstu izrade Strategije upravljanja gradskom imovinom držimo izrazito korisnim napomenuti kako je poželjno voditi računa i o nekretninama u vlasništvu javnih ustanova kojima je Grad osnivač jer se, usprkos činjenici da su javne ustanove često vlasnici nekretnina koje koriste, troškovi održavanja i poboljšavanja istih vrlo često podmiruju upravo na teret gradskog proračuna. Nažalost, pored obavljanja poslova iz svoje zakonske nadležnosti, odnosno aktiviranja nekretnina u smislu stjecanja prihoda i njihove gospodarske iskoristivosti, ponekad se nekretnine mogu naći u ulozi sredstva osiguranja različitih tražbina na način da se na njima osnuje prisilno ili dobrovoljno založno pravo, a koje okolnosti je potrebno evidentirati i pratiti s obzirom na to da mogu biti od značajnog utjecaja na raspolaganje i upravljanje nekretninama u najširem smislu.

Uvažavajući naprijed navedeno, može se zaključiti kako je dovoljan čak i površan pregled problematike upravljanja nekretninama kako bi se utvrdilo da je riječ o izrazito kompleksnom i dinamičnom području koje zahtijeva značajan angažman stručnjaka različitih profila. Takvom mišljenju u prilog ide i okolnost kako upravljanje nekretninama na način da se iste dodjeljuju na korištenje sportskim klubovima, organizacijama civilnog društva ili političkim strankama, pored stručnog i operativnog, može postati osjetljivo pitanje od prvorazrednog političkog značaja sa značajnim i dalekosežnim posljedicama po širu društvenu zajednicu.

Zaključno u ovom dijelu, a uvažavajući naprijed navedeno te okolnost kako, nažalost, za mnoge jedinice nepokretne imovine na području čitave Republike Hrvatske nisu sređeni imovinskopravni odnosi, evidentiranje nekretnina i izradu strategije upravljanja možemo promatrati kao važan iskorak sređivanju upravo tih odnosa, koji s druge strane predstavljaju prijeko potreban uvjet u bilo kojem značajnijem infrastrukturnom projektu.

3.2. Vrijednosti i struktura nekretnina u vlasništvu gradova

Državni ured za reviziju obavio je te objavio u ožujku 2016. godine reviziju učinkovitosti upravljanja i raspolaganja nekretninama u vlasništvu lokalnih jedinica. Postupci revizije provedeni su tijekom 2015. i početkom 2016. godine, a revizijom su obuhvaćene aktivnosti od

2012. do 2014. godine, a za pojedina područja revizije obuhvaćene su aktivnosti u ranijim razdobljima 2015. godine (DUZ, 2016.). Revizijom su obuhvaćene sve lokalne jedinice u Republici Hrvatskoj, uključujući svih 127 gradova, te Grad Zagreb koji je u posebnom statusu.

Na kraju 2014. godine lokalne jedinice u Republici Hrvatskoj su upravljale i raspolagale s 22.425 poslovnih prostora ukupne površine 3.613.966 $m^{2.}$. Također, na raspolaganju im je 18.371 stan ukupne površine od 933.762 m^2, te građevinska zemljišta ukupne površine 338.174.458 m^2 (DUZ, 2016.)

U sljedećoj tablici nalaze se podaci o broju i površini poslovnih prostora i stanova te površini zemljišta lokalnih jedinica na dan 31.12.2014. godine.

Tablica 3-1: Količina poslovnih prostora, stanova te zemljišta lokalnih jedinica na dan 31.12.2014. prema razinama lokalne vlasti

Razina lokalne vlasti	Broj lokalnih jedinica	Poslovni prostori		Stanovi		Površina zemljišta (m2)
		Broj	Površina (m2)	Broj	Površina (m2)	
Gradovi	127	11.734	1.664.664	9478	463.155	150.730.426
Grad Zagreb	1	4170	610.337	7504	397.273	24.900.202
Županije	20	300	225.484	29	1708	1.587.038
Općine	428	6221	1.113.481	1360	71.626	160.956.792
Ukupno	**576**	**22.425**	**3.613.966**	**18.371**	**933.762**	**338.174.458**

Izvor: Državni ured za reviziju, revizija učinkovitosti (2016.)

U Republici Hrvatskoj ukupno 128 gradova, uključujući Grad Zagreb, upravlja iznimno velikim, vrijednim, raznolikim, ali nedovoljno iskorištenim portfeljom nekretnina. Gradovi u RH upravljaju s gotovo 16 tisuća poslovnih prostora površine veće od 2,25 milijuna metara kvadratnih. Isto tako, upravljaju s gotovo 17 tisuća stanova ukupne površine veće od 860 tisuća metara kvadratnih, te sa zemljištima površine oko 175 milijuna metara kvadratnih.

Iako predstavljaju manje od četvrtine administrativnih jedinica u RH (22%), gradovi upravljaju s više od polovice poslovnih prostora i stanova (52%), te promatrano prema površini prostora upravljaju gotovo s polovicom površine poslovnih prostora (46%), stanova (49%), te zemljišta (45%). Kada u skupinu gradova uključimo Grad Zagreb koji ima poseban status, dominacija gradova među lokalnim administrativnim jedinicama još je čvršća. U tom slučaju, gradovi upravljaju s gotovo tri četvrtine poslovnih prostora (71%) i gotovo svim stanovima (92%).

Promatrano prema kvadraturi prostora gradovi, uključujući i Grad Zagreb, upravljaju s 63% ukupne površine poslovnih prostora (63%), impozantnih 92% ukupne površine svih stanova te više od polovice svih zemljišta (52%).

Jedinice lokalne samouprave upravljaju i raspolažu sljedećim poslovnim prostorima: poslovne zgrade, mjesni i vatrogasni domovi i poslovne prostorije, a u slučaju Grada Zagreba i garaže. Prosječna površina poslovnih prostora kojima upravljaju gradovi i predmet su ove disertacije iznosi 143 m2. Grad Zagreb je krajem 2014. godine upravljao s 4170 poslovna prostora i 7504 stanova. 1198 poslovnih prostora i 878 stanova koriste se na temelju ugovora o zakupu ili najmu sa Zagrebačkim Holdingom (dalje: ZGH), trgovačkim društvom u vlasništvu grada. Dotični ugovori zaključeni su 2008. i 2013. na rok od 10 ili 15 godina, a za korištenje predmetnih prostora i stanova Grad Zagreb plaća zakupninu (najamninu) i po isteku ugovora stječe vlasništvo nad njima. Među ostalim gradovima, najveći broj poslovnih prostora imaju Rijeka (1842), Split (822), Pula (662), Zadar (455) i Osijek (385).

Za potrebe ove disertacije, autor je proveo istraživanje o vrijednosti nekretnina gradova, prihodima od nekretnina, te vrijednosti imovine *per capita* koji su prikazani u nastavku. Najveću vrijednost nekretnina od više od 8 milijardi kuna iskazuje Grad Pula, slijedi Grad Rijeka s gotovo 7 milijardi kuna vrijednim nekretninama. Na treće mjesto smjestio se Grad Zagreb s nekretninama vrijednim više od 6 milijardi kuna, slijede Dubrovnik (5,3 mlrd. kn) i Split (4 mlrd. kn) na četvrtom i petom mjestu. Nekretnine ukupne vrijednosti iznad milijarde kuna još posjeduju Umag, Osijek, Mali Lošinj i Slavonski Brod. Dakle, od ukupno 126 gradova obuhvaćenih istraživanjem, njih 9 posjeduje portfelj nekretnina vrjedniji od milijardu kuna. Sljedećih 48 gradova ima portfelj vrjedniji od sto milijuna kuna. U toj kategoriji prednjači Zadar (736 mil. kn), slijede ga Vinkovci(699 mil. kn), Rovinj (699 mil. kn), i Varaždin (642 mil. kn), a na začelju te kategorije nalazi se Pakrac (106 mil. kn), iz Požeško-slavonske županije.

Grafikon 3-1 Vrijednost nekretnina u vlasništvu gradova u RH na dan 31.12.2016. godine u kunama

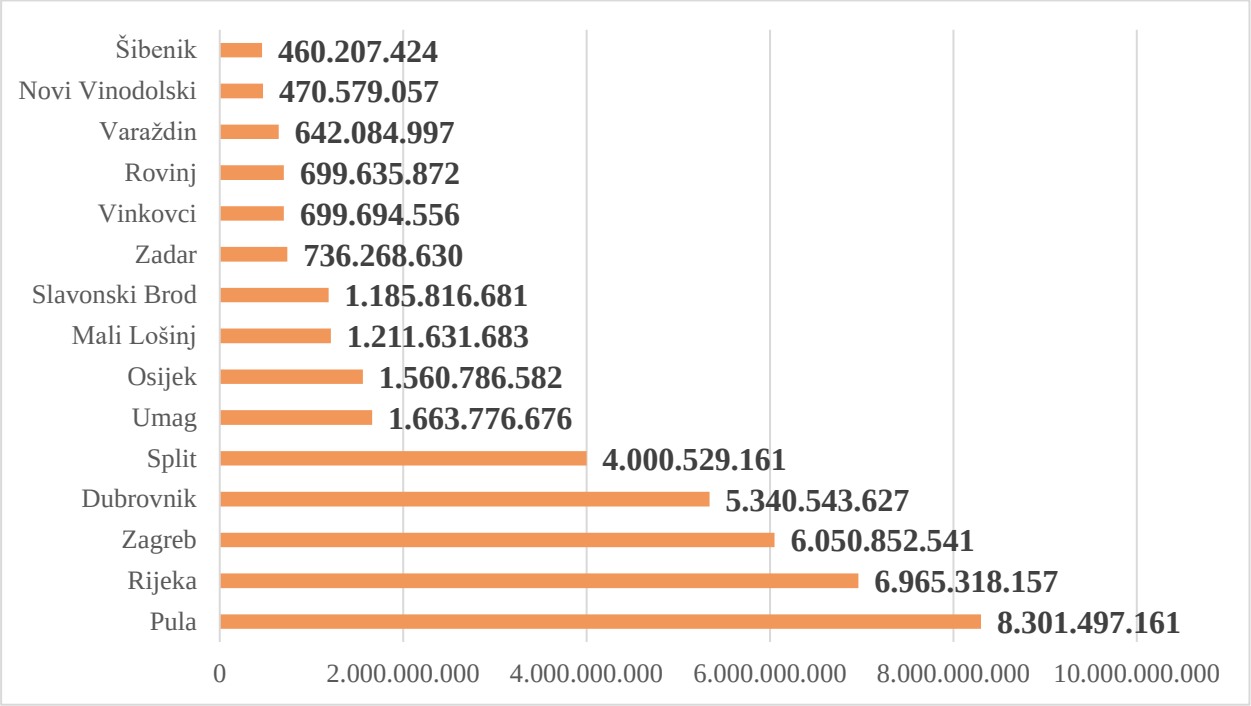

Izvor: Izračun autora

Grafikon 3-2 Relativni udio prvih deset gradova prema vrijednost nekretnina u njihovom vlasništvu na dan 31.12.2016. godine

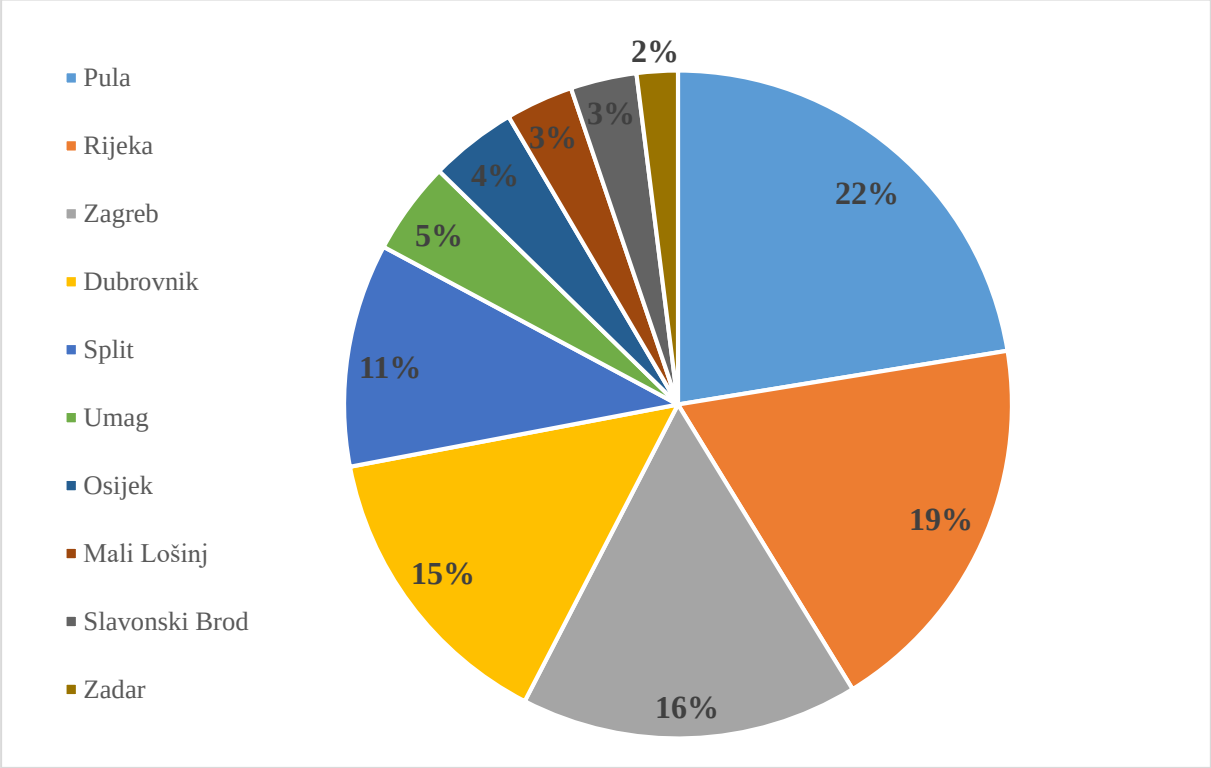

Izvor: Izračun autora

U posljednjoj kategoriji nalaze se gradovi s vrijednošću nekretnina manjom od 100 milijuna kuna, te ih je ukupno 69. Gradovi s najmanjom vrijednošću nekretnina su Klanjec (4 mil. kn), Skradin (9 mil. kn) i Benkovac (10 mil. kn).

Grafikon 3-3 Vrijednost nekretnina u vlasništvu gradova u 2017. u kunama - posljednjih 10

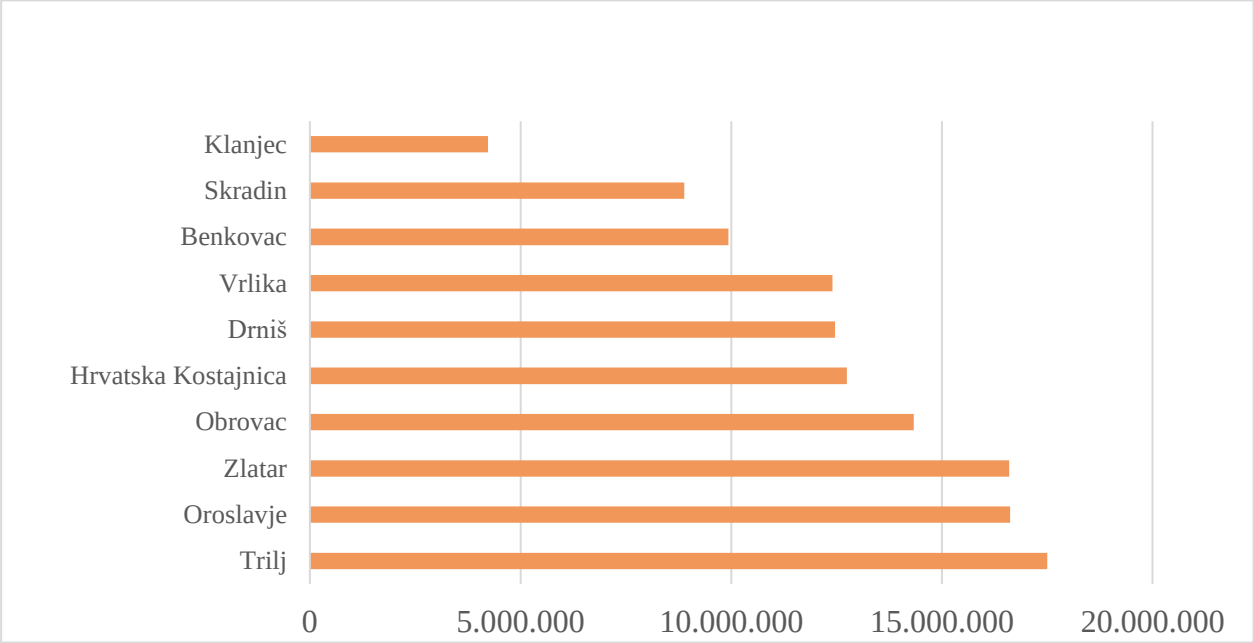

Izvor: Izračun autora

Ukupno je 126 (od 128) gradova u RH obuhvaćenih ovim istraživanjem, uključujući i Grad Zagreb u 2017. godini ostvarilo ukupne prihode od nekretnina nešto veće od milijardu kuna (1,08 mlrd). Ovdje valja napomenuti da je ukupna vrijednost svih nekretnina u vlasništvu 126 gradova koji su predmet autorovog istraživanja oko 53,6 milijardi kuna iz čega je jednostavno izračunati da nekretnine u vlasništvu hrvatskih gradova godišnje donose prinos od skromnih 2%.

Od ukupnih prihoda od nekretnina koje ostvaruju hrvatski gradovi, prednjači glavni grad Republike Hrvatske, Grad Zagreb s ostvarenih gotovo 288 milijuna kuna prihoda s te osnove. Slijede Rijeka (110 mil. kn), Split (81 mil. kn), Pula (51 mil. kn), Osijek (47 mil. kn), Dubrovnik (46 mil. kn), Zadar (41 mil. kn), Poreč (27 mil. kn), Varaždin (24 mil. kn), Opatija (19 mil. kn). Svi ostali gradovi (116) ostvarili su 347 milijuna kuna prihoda od nekretnina u 2017. godini. Najviši prinos od nekretnina u odnosu na vrijednost nekretnina u 2017. godini ostvarili su Obrovac (21%) i Benkovac (20%), a slijede Trogir (20%), Omiš (20%) i Supetar (13%).

Riječ je o gradovima koji imaju vrijednost nekretnina manju od 100 milijuna kuna, od čega najmanju vrijednost imaju prvoplasirani Obrovac (14 mil kn) i Benkovac (9 mil. kn). U kategoriji gradova s vrijednošću nekretnina od 100 milijuna kuna do milijarde kuna, najbolje stoji Grad Nin koji s ukupnom vrijednošću nekretnina od 172 milijuna kuna ostvaruje prinos od 6,5%, odnosno 11,3 milijuna kuna u 2017. godini. Slijedi Grad Poreč koji s nekretninama vrijednim ukupno 443 milijuna kuna ostvaruje prinos od 6%, odnosno ukupno gotovo 27 milijuna kuna, a zatim slijede Opatija (5,5%), Zadar (5,5%) i Čakovec (4,8%).

Od gradova iz kategorije čija ukupna vrijednost nekretnina u 2017. godini iznosi preko milijardu kuna, predvodi Grad Zagreb s prinosom od 4,8% što znači da je na portfelju nekretnina vrijednom preko 6 milijardi kuna ostvario ukupne prihode od gotovo 288 milijuna kuna. Slijede Osijek (3%) koji ostvaruje prinos od 47 milijuna kuna na vrijednost nekretnina od preko milijardu i pol kuna. Ostali gradovi s nekretninama ukupne vrijednosti veće od milijardu kuna ostvaruju prinose na razini 2% godišnje ili niže (Split – 2%; Rijeka – 1,6%; Slavonski Brod – 1%; Umag – 0,9%, Dubrovnik – 0,9%)

Grafikon 3-4:Relativni udio gradova u ostvarenom ukupnom prihodu od nekretnina u 2017. godini

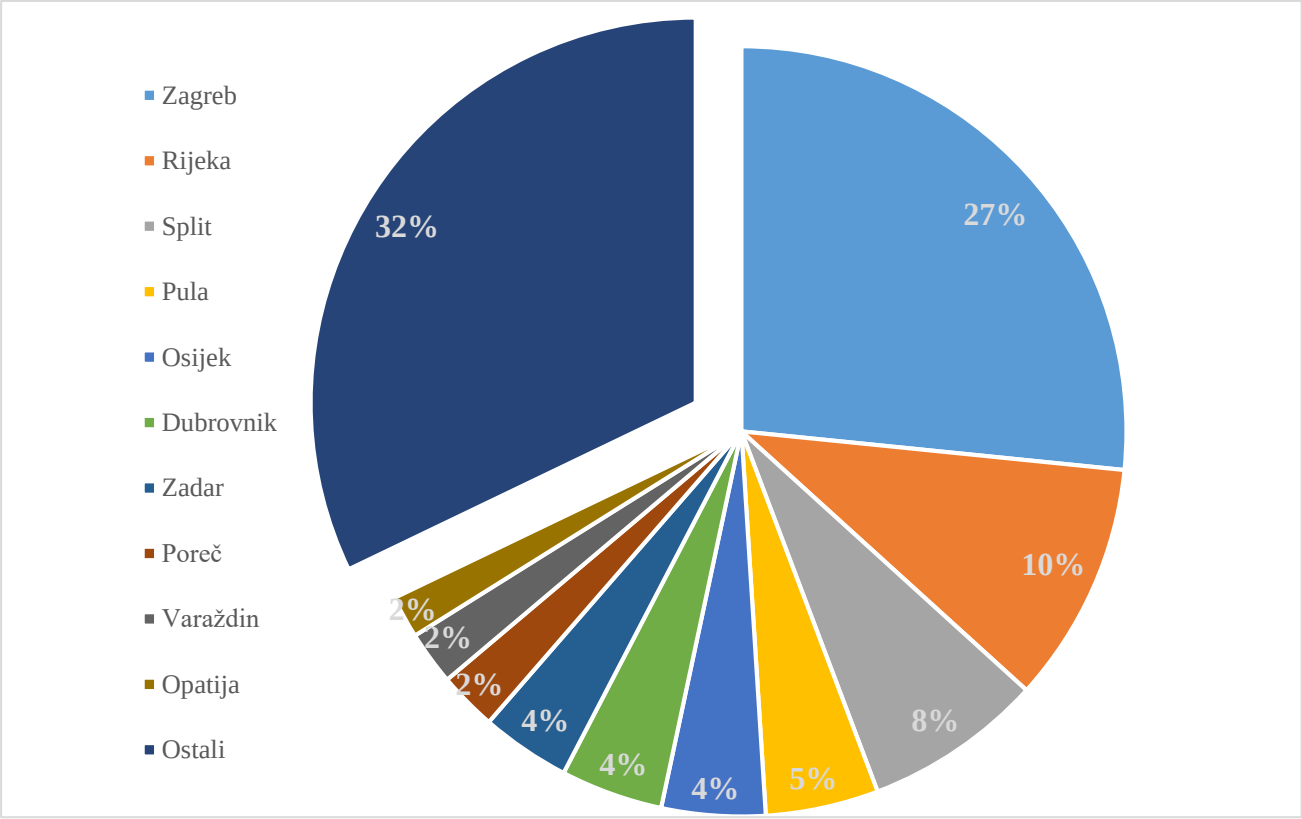

Izvor: Izračun autora

Rezultati istraživanja pokazuju promatrano iz relativne perspektive da Zagreb ostvaruje 27% od ukupnog prinosa koji iznosi 1,08 mlrd. kuna. Rijeka uprihođuje 10% tog "kolača", slijede Split (8%), Pula (5%), Osijek, Dubrovnik i Zadar (4%). Ostalih 116 gradova RH ostvaruje ukupno 32% ukupnih prihoda.

Grafikon 3-5 Vrijednost imovine po stanovniku u 2016. godine u tisućama kuna - prvih 15 gradova

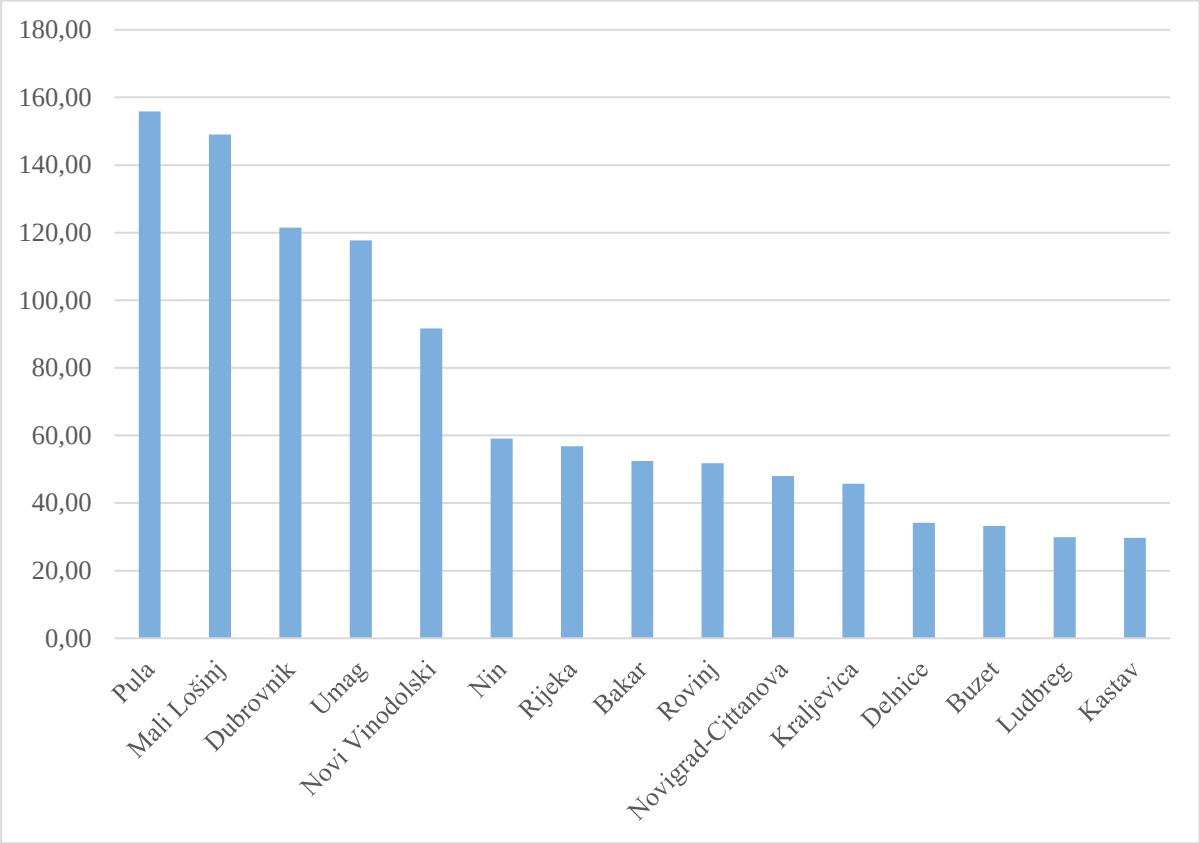

Izvor: Izračun autora

Najvišu vrijednost imovine po broju stanovnika ima Pula (156 tisuća kuna po stanovniku). Slijede Mali Lošinj, Dubrovnik, Umag i Novi Vinodolski. Zanimljiv je podatak da vrijednost nekretnina Grada Zagreba po stanovniku iznosi 9300 kuna.

Grafikon 3-6 Vrijednost imovine grada per capita u 2016. godini u tisućama kuna - izabrani gradovi

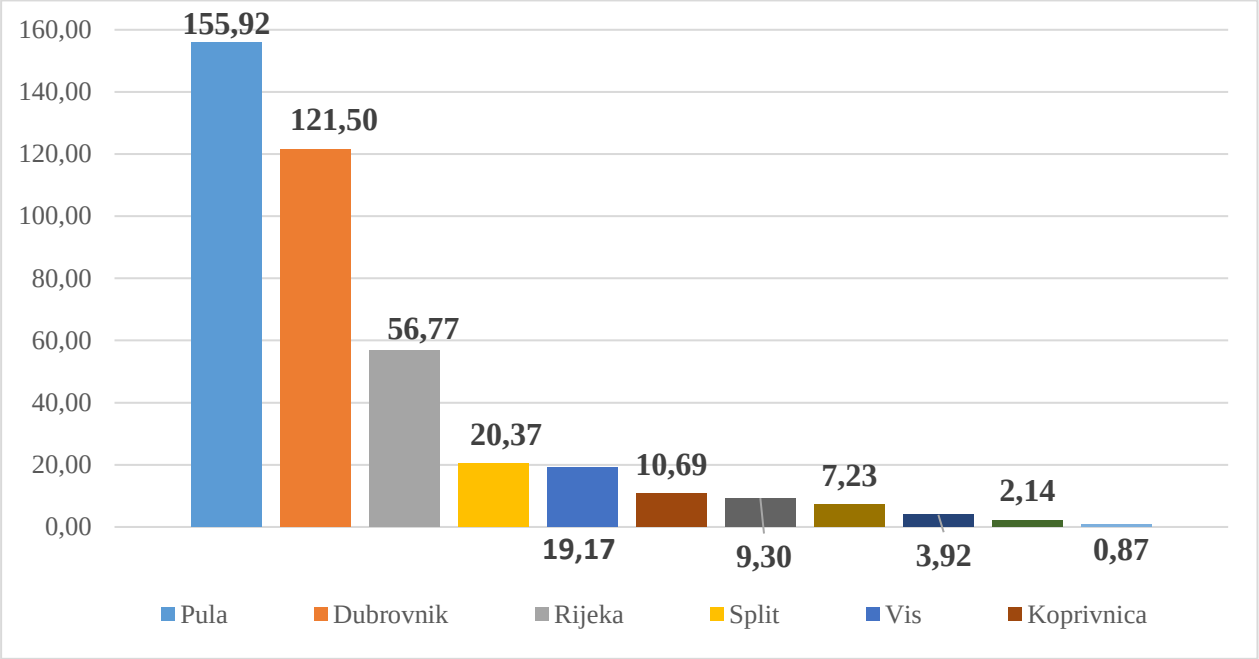

Izvor: Izračun autora

3.3. Praksa i modeli upravljanja imovinom u gradovima kroz Projekt reforme lokalne samouprave (PRLS Model)

Većina stručnjaka slaže se da je upravljanje nekretninama u vlasništvu JLP(R)S na nezadovoljavajućoj razini u smislu sustavnog pristupa problemu. Kao opću karakteristiku naglašavaju nisku razinu razumijevanja značaja nekretnina u vlasništvu i poznavanja vlastitog vlasništva. Nema prepoznatog sustava upravljanja nekretninama, upravljanje je mjestimično, razlikuje se od jedinice do jedinice te uvelike ovisi o djelatnicima gradova i općina i njihovoj osobnoj motivaciji. Takvo neuređeno stanje pogoduje razvoju sive zone koja donosi niz specifičnih problema. Kaganova radi razliku između gradova koji provode projekt upravljanja imovinom, a koji većinom lijepo napreduju, i jedinica lokalne samouprave koje nisu pokrenule takve aktivnosti i kod kojih je praksa nezadovoljavajuća. (Guszak, 2007.)

Ovo poglavlje predstavlja i analizira Projekt reforme lokalne samouprave (PRLS) kojemu je svrha pružiti tehničku pomoć s dva cilja:

1. unapređenje upravljačke sposobnosti lokalnih samouprava
2. savjetovanje Vlade Republike Hrvatske u vezi s reformom lokalne samouprave.

Projekt provodi The Urban Institute, neprofitna istraživačka i savjetodavna organizacija iz Washingtona koju financira Američka organizacija za međunarodni razvoj (USAID). U zadnje je vrijeme u sklopu projekta razvijeno pet modela upravljanja prilagođenih potrebama loklanih samouprava s ciljem unapređenja upravljanja postojećim resursima.

Jedan od modela odnosi se na upravljanje imovinom kroz sustavni pristup povećanju učinkovitog iskorištavanja imovine u vlasništvu ili na raspolaganju lokalnih samouprava. U prvome koraku je potrebno provesti sveobuhvatnu inventuru svih jedinica imovine i određivanje primjene od koje će lokalna samouprava imati najviše koristi. Nakon toga model se bavi pitanjima upravljanja imovinom uvođenjem metoda za procjenu imovine, analizu izravnih i neizravnih subvencija, razrade operativnih izvješća za pojedinačne jedinice imovine, itd. Model svojim multidisciplinarnim pristupom donosi poboljšanja u lokalnim financijama i pružanju usluga što sa sobom donosi i unapređenje lokalnog gospodarskog razvoja.

Hrvoje Bertović, Olga Kaganova i John Rutledge objavili su 2004. Priručnik za upravljanje imovinom kao diseminaciju modela upravljanja imovinom u vlasništvu lokalne samoprave u Republici Hrvatskoj s ciljem olakšanja njegove primjene. Priručnik je sinteza teoretskih i pratkičkih tema i pruža konkretne smjernice za akciju na temelju prokušanih međunarodnih praksa razvijenih od strane stručnjaka The Urban Institutea na zahtjev Svjetske Banke i provedenih kroz projekte u zemljama s novonastalim tržištima u Europi i Aziji, kao i pilot gradovima u Republici Hrvatskoj.

Složenost upravljanja nekretninama u vlasništvu gradova i nisku razinu razvijenosti sustava potvrđuju stručnjaci vrlo različitim i širokim problemima koje navode. Ključne poteškoće upravljanja nekretninama gradova u Hrvatskoj koje su stručnjaci identificirali počinju nepoznavanjem što sve gradovi zaista posjeduju, u vlasništvu ili na raspolaganju. JLP(R)S su slovom pera dobili raznu imovinu, nisu bili svjesni niti su se borili da dođu do svake pojedinačne nekretnine i sad su u situaciji da imaju sve više nekretnina, ne znaju što sve imaju, ne znaju što će s tim nekretninama, a poneke im čak i smetaju.

Slijedi tretiranje nekretnina kao javnog dobra, umjesto kao produktivnog sredstva za postizanje određenih ciljeva. Pri tome JLP(R)S ne prepoznaju koristi prepuštanja pojedinih aktivnosti privatnom sektoru, zbog navike žele zadržati kontrolu nad što više aktivnosti, a time i nad puno

nekretnina nepotrebnih za temeljne funkcije JLP(R)S. Poslovanje JLP(R)S i upravljanje nekretninama zasigurno bi olakšala primjena pozitivnih iskustava i principa iz privatne prakse. Ključni je naglasak na primjeni tržišnih principa upravljanja i razumijevanje ekonomije tržišta nekretnina. Međutim, nedostatak tradicije sustavnog i tržišnog upravljanja usporava primjenu tih principa. Zaposlenici JLP(R)S tek uče koje su suvremene metode i principi upravljanja nekretninama. Ozbiljan problem su nedostatna educiranost, sposobnost i motiviranost zaposlenika za poslove upravljanja nekretninama. Znanja postoje, ali su nesistematizirana. Upravljanje nekretninama je dodatno opterećenje operativne razine, što je više nekretnina, to zaduženi zaposlenici JLP(R)S imaju više posla i glavobolja s njima, sve dok ih netko ne prisili. Na to se nastavlja potreba formalnog organiziranja posebnih organizacijskih jedinica zaduženih za poslove upravljanja nekretninama JLP(R)S i ekipiranje stručnim i motiviranim djelatnicima.

Iz financijske perspektive, John K. Rutledge naglašava nedostatak financijskih i računovodstvenih podataka na razini jedinice imovine. To je prvenstveno tržišna vrijednost jedinica nepokretne imovine, koja je redovito nepoznata jedinicama lokalne samouprave. Sljedeća dimenzija su prihodi i troškovi koji nastaju vezano za pojedinu jedinicu nepokretne imovine. Bez podatka o vrijednosti i financijskom rezultatu pojedine nekretnine, ne postoje temelji za učinkovito odlučivanje o optimalnom raspolaganju tom nekretninom. Konačno, ograničavajući faktor je i neprimjerena zakonska regulativa. S jedne strane nedostatak provedbenih propisa, a s druge donošenje zakona koji nisu usklađeni s realnim stanjem i potrebama jedinica lokalne samouprave. Središnja država dodatno otežava upravljanje nekretninama gradova svjesnom željom i nastojanjima da zadrži nadzor nad određenim resursima. Dio odgovornosti snosi i sudbena vlast, za nerazumijevanje, sporost, tromost, nezainteresiranost i neučinkovitost rješavanja predmeta iz područja upravljanja nekretninama.

To se prvenstveno odnosi na pitanja povrata imovine, koja se rješavaju godinama, tijekom kojih lokalne jedinice trpe gubitke, umjesto da su takve jedinice imovine stavljene u funkciju korištenja. (Guszak, 2007.)

Jedinice lokalne samouprave Republike Hrvatske zapošljavaju inženjere, ekonomiste, pravnike i računovođe te koriste usluge vanjskih stručnjaka kao što su upravitelji nekretninama, procjenjitelji, odvjetnici, itd. Svi zajedno posjeduju brojne vještine potrebne za dobro upravljanje imovinom, a cilj je više navedenog priručnika (Bertović, 2004.) ustrojiti sustav koji bi integrirao rad svih tih stručnjaka i njihove profesionalne vještine, znanja i iskustva.

Raznolikost praksa koje trenutačno nalazimo u Republici Hrvatskoj povećava važnost toga zadatka zbog čega ćemo u nastavku predstaviti načelne razloge za poboljšanje upravljanja imovinom u vlasništvu lokalnih samouprava u Hrvatskoj i sadržaj portfelja imovine, kao i preporuke za sustavan pristup upravljanju imovinom. Adekvatan model upravljanja imovinom pomaže jedinicama lokalno samouprave da definiraju sadržaj svojih portfelja nekretnina i nastavno na to upravljaju i prate njihove financijske učinke.

Lokalne samouprave mogu svojom imovinom učinkovito upravljati samo slijedeći dobre prakse iz privatnog sektora (Bertović, 2004.):

- upravljanje, računovodstvo, izrada proračuna i radovi planirani prema pojedinoj jedinici imovine;
- ažurne i relevantne baze podataka o fizičkim, operativnim i financijskim značajkama nekretnina
- evidencija parametara relevantnih za privatno tržište, poput tržišne vrijednosti nekretnina
- pridržavanje standarda aktualnih financijskih instrumenata i rezultata na tržištu nekretnina (npr. obračuni povrata na ulaganja i kapitalizacija)
- učinkoviti natječaji za zakup, prodaju i nabavu usluga i materijala
- prodaja određenih nekretnina u svrhu učinkovitijeg upravljanja ukupnim portfeljem.

Da bi jedinica lokalne samouprave primijenila ovu praksu na upravljanje svojom imovinom, mora poduzeti sljedeće korake (Bertović, 2004.)

- Uspostava odjela za upravljanje imovinom: centraliziranje odgovornosti tako da jedan odjel i dužnosnici u sklopu odjela budu odgovorni za rezultate upravljanja imovinom.
- Određivanje strateške uoge nekretnina u ciljevima lokalne samouprave: ciljevi se mogu odnositi na što učinkovitije pružanje obaveznih usluga, ostvarivanje prihoda za financiranje projekata lokalne samouprave, unaprijeđenje kulturnog života, poboljšanje izgleda grada, smanjivanje subvencija nevladinim organizacijama i socijalnim korisnicima imovine.
- Podjela (klasifikacija) nekretnina u sprezi sa zadacima lokalne samouprave: odluke o zadržavanju ili raspolaganju pojedinom nekretninom, financijskoj politici i odgovornosti trebaju se donositi na temelju funkcije i načina korištenja nekretnine.

Koristi li se nekretnina za, primjerice, rad lokalne samouprave ili kulturna događanja, utječe na to kako je s njom najbolje upravljati.

- Izrada i ažuriranje baze podataka o imovini: upravljanje imovinom oslanja se i uvelike ovisi o točnim i iscrpnim podacima o nekretninama. Neki od njih su stalni, poput adresa i fizičkih osobina, i nisu podložni promjenama, ali financijski rezultati i zauzeće mijenjaju se često zbog čega je ažurnost baze podataka od iznimne važnosti.
- Uvođenje prakse upravljanja imovinom prema standardima upravljanja portfeljima: nakon određivanja ciljeva i uspostave organizacije potrebno je uvesti cjelovitu praksu upravljanja imovinom. Zato je važno da upravitelji (odjel za upravljanje) zadane ciljeve izvršavaju praćenjem dnevnih i mjesečnih rezultata te planiranjem i izvršavanjem dugoročnih strategija.

PRLS-ov model upravljanja imovinom sastoji se od sljedećih jedanaest aktivnosti (Bertović, 2004.):

1. uvođenje baze podataka/sustava inventure za svaku jedinicu imovine posebno
2. povrat imovine
3. klasifikacija imovine i formuliranje financijske politike u skladu s klasifikacijom
4. procjena nekretnina
5. računovodstvo i financijsko planiranje za imovinu (operativni izvještaji za jedinice imovine ili portfelja)
6. intenzivna financijska analiza projekata, imovine i portfelja
7. deregulacija poslovnoga zakupa i poboljšanje postupaka iznajmljivanja
8. kvantificiranje i praćenje direktnih i indirektnih subvencija vezanih za nekretnine koje uživaju zakupci i korisnici nekretnina u vlasništvu lokalne samouprave
9. izvještavanje o imovini
10. konsolidiranje upravljanja
11. izrada sveobuhvatnog plana za upravljanje imovinom.

U nastavku rada opisat će se sve nabrojane aktivnosti PRLS modela.

- **Aktivnost 1.: Uvođenje novoga sustava obrade podataka za svaku jedinicu imovine posebno**

U gospodarenju imovinom često se koriste različiti mogući načini kako bi prikupili osnovne podatke koje nakon obrade koristi za racionalno i učinkovito upravljanje imovinom i tu lokalne jedinice nisu iznimka. No postoje različita negativna mišljenja protiv takvih nastojanja. Prvenstveno, tu je argument kako će prikupljanje podataka koje će činiti cjeloviti i ispravni popis zapravo vremenski iscrpna aktivnost koja stavlja dodatni teret resursima lokalne samouprave koji su poprilično ograničeni. Isto tako, postoji rasprava o pitanju koju imovinu je zaista potrebno popisivati, a koju unatoč tome što su neosporno u vlasništvu JLS ne treba. Neosporno, uspostavljanje baze podataka s cjelovitim i ispravnim popisom imovine iznimno je značajan temelj za izgradnju efikasnog sustava upravljanja imovinom. Uspostava nadzora i mogućnost analize vlastitih nekretnina nije moguć bez detaljne baze podataka. Također, na temelju takvih podataka moguće je primijeniti strateški plan za upravljanje različitim vrstama imovine. Postoje i drugi faktori koji idu u prilog popisivanju: (Bertović, 2004.):

- prikupljanje podataka nužno je za dobro gospodarenje javnom imovinom, kao i kontrola u nekim slučajevima;
- prikupljanje podataka o imovini je propisano zakonom;
- nije moguće izdati municipalne obveznice bez organiziranog prikupljanja podataka;
- prikupljanje podataka jamči višu razinu transparentnosti.

Zaključno, troškovi koji nastaju organiziranjem popisa mogu se pokriti iz vlastite posljedice – efikasnijeg upravljanja javnom imovinom što će zbog efikasnijeg i učestalijeg korištenja rezultirati povećanjem proračunskih prihoda.

Prema priručniku popis imovine sadržava dvije kategorije informacija. S jedne strane mora sadržavati realni popis imovine dok s druge strane, potrebno je uključiti podatke koje se odnose na računovodstveni i financijski aspekt. Prema priručniku popis imovine i računovodstveni dijelovi sadržavaju sljedeće:

POPIS IMOVINE

- identifikacija nekretnine
- površina
- opisni dio
- namjena
- potencijalna ograničenja vezana uz namjenu nekretnine
- potencijalne namjene nekretnine
- ingerencija upravljanja

KNJIGOVODSTVO

- korisnici nekretnine
- postoci u kojim se nekretnina koristi
- podaci vezani uz najam
- prihodi i troškovi nastali upravljanjem nekretnine
- vrijednost nekretnine i eventualni financijski tereti ukoliko postoje

Gore navedeni podaci se trebaju odnositi na nekretninu u cijelosti, a ne parcijalno.

Većinski broj JLS neke od ranije nabrojanih kategorija podataka ne prati kako bi trebalo na razini zasebnih jedinica imovine. Način na koji se izrađuju proračuni i tradicionalno knjigovodstvo koje se koristi nemaju fokus na takvoj obradi. Stoga je često komplicirana situacija s evidentiranjem prihoda i troškova. Nerijetko se događa kako više tijela kojima je nadležna ista jedinica lokalne samouprave iz lokalnog proračuna imaju doznačena sredstva kojima trebaju pokrivati razne tekuće troškove te troškove održavanja različitih jedinica imovine. To rezultira time da troškove održavanja za neku jedinicu imovine u praksi plaćaju različita tijela dok istovremeno neka od njih ne bilježe na koju imovinu troše doznačena sredstva. Na prihodovnoj strani javljaju se slučajevi kada stanari ostvaruju prihod od imovinske jedinice u vlasništvu JLS, a pritom vlasnik (JLS) o tome prihodu nema informaciju da je takav prihod ostvaren te nastavlja subvencionirati stanara. Dobar primjer su sportski klubovi koji često na korištenje dobiju dvoranu ili stadion u gradskom vlasništvu. Oni dijelove te jedinice imovine daju u podzakup od čega ostvaruju prihode, a istovremeno ostvaruju i prihode iz proračuna JLS za održavanje.

Gotovo uvijek se prihodi o svakoj pojedinoj jedinici imovine mogu izvući, ali često je to vrlo zahtjevan posao. Ukoliko želi efikasno upravljati imovinom za vlasnika je iznimno značajno

pratiti sveukupne prihode i rashode svake konkretne imovinske jedinice.

Onaj tko upravlja imovinom i djeluje u ime vlasnika (ne mora nužno biti sam vlasnik) može biti zadužen za prikupljanje svih prihoda te plaćanja troškova. S tom organizacijom je potrebno ugovorno regulirati hoće li dobit prebaciti vlasniku ili ju zadržati kao subvenciju. Kako god, upravitelj će voditi potpunu knjigovodstvenu evidenciju. Na taj način vlasniku postaju dostupni cjeloviti podacima o tome koje rezultate ostvaruje svaka jedinica imovine. Takvim podacima moguće je uključiti i ostale izdatke vezane uz tu jedinicu.

Vlasniku jedinice imovine je manje relevantno posjedovati sve podatke o njenim izdacima ukoliko je zakupom definirano da korisnici podmiruju sve troškove i plaćaju dogovorenu zakupninu. Primjerice u zemljama zapadnog svijeta uobičajena je praksa da se gospodarski objekti daju zakupcima po cijeni neto zakupa uvjetovano da se korisnika tereti za plaćanje svih poreznih davanja, reparaciju i održavanje, troškove uređenja okoliša, osiguranje i slično. Vlasnik treba znati da se svi troškovi redovito plaćaju te da se imovinska jedinica održava na način propisan ugovorom no stvarne troškove bilježi korisnik. Manje je važno s financijskog aspekta plaća li zakupac bruto zakupninu vlasniku koji podmiruje sve troškove ili se plaća neto zakupnina u modelu u kojem obavezu podmirivanja troškova ima zakupac. Trošak je posve jednak u oba navedena slučaja. Gledajući s druge strane, vjerojatno je bolje kada zakupac ima obavezu podmirivanja troškova jer tako sam ugovara poslove te ih može nadzirati. Isto tako, on može sam obaviti određene poslove održavanja zasigurno po cijeni nižoj od one koje bi odredio vanjski izvođač radova.

Postoji razlika između stvarno ostvarenih troškova i potrebnih troškova koja se promatra na razini godine dana. U slučaju kada su potrebni troškovi viši od onih ostvarenih održavanjem, akumulacijom može doći do propadanja jedinice imovine. Zapravo je riječ o nakupljenom odgođenom ulaganju i razumijevanje tog problema iznimno je značajno i za razumijevanje upravljanja imovinom u cjelini. Za održavanje vrijednosti nekretnine na razini da ne gubi vrijednost nužno je uspješno upravljati imovinom za što je kvaliteta održavanja svake pojedine imovinske jedinice krucijalna. Ako je riječ o imovini za iznajmljivanje, to će privući nove potencijalne korisnike što otvara mogućnost bržeg najma po odgovarajućoj cijeni za vlasnika. Provedba popravaka i zamjena treba organizirati obzirom na vijek trajanja. Ukoliko dođe do akumuliranog odgođenog održavanja, to bi trebalo pokrenuti značajne i jake odluke poput

prodaje imovine koja se ne može kvalitetno održavati, te smanjivanje subvencija i provedba revizije prioriteta proračuna.(Bertović 2004.)

Pregledi i kontrola jedinica imovina u svrhu provjere kvalitete održavanja su značajan zadatak upravitelja imovinom. Premala ulaganja moguće je identificirati kroz računovodstvene i financijske pokazatelje, no pregled daje konkretniju i bržu informaciju On treba biti fokusiran na one elemente koji su podložni promjenama od posljednjeg obavljene kontrole.Tako prikupljeni podaci koriste se za izradu analize potrebe i iznosa izdataka, postepeno povećanje prihoda od zakupa te identifikaciju jedinica koje u zadanom trenutku ne ostvaruju povoljne rezultate s ciljem odabira mjera za poboljšanje. Najracionalnije je početi primjenjivati novi sustav prikupljanja i obrade podataka sa značajnijim i većim jedinicama koje ostvaruju prihod od iznajmljivanja.

Zaključno, važno za uspješnost u kontinuiranom procesu popisivanja imovine je biti predan poslu i ostvarivanju napretka. Svaki mali korak je važan, a savršenstvo je ionako nemoguće postići.

- **Aktivnost 2.: Tranzicijska pitanja**

U Republici Hrvatskoj su i dalje u tijeku procesi koje možemo nazivati tranzicijskima, a koji s aspekta upravljanja imovinom zahtijevaju pažnju odgovornih ljudi u JLS. Vlasništvo nad imovinom podijeljeno je između središnje države te lokalnih samouprava. Početkom devedesetih godina prošlog stoljeća formiran je veliki broj novih jedinica lokalne samouprave. Također postoji značajan broj bivših vlasnika jedinica imovine koji su u procesu vraćanja vlasničkih prava izgubljenih u prošlosti konfiskacijom ili nacionalizacijom.

Kada govorimo o povratu imovine, nužno je biti pragmatičan u rješavanju praktičnih pitanja. Ako imovina u procesu povrata ne ostvaruje dohodak, potrebno je poduzeti raspoložive mjere za ubrzanje tog procesa. Najvažnije pitanje je želi li i koliko je spremna JLS ulagati u svoju imovinu, u popravke i tekuće održavanje jedinica imovine koje će vrlo vjerojatno biti primorana vratiti prijašnjim vlasnicima. Logično je postavljati pitanje o stupnju spremnosti ulaganja u vlastitu imovinu i onu za povrat. Također se isto pitanje treba postaviti o spremnosti na ulaganje

u one nekretnine koje nisu u vlasništvu JLS, ali ih podupire materijalno, primjerice imovina kulturnih institucija. Treba li jednako ulagati u tu kategoriju imovine kao i u vlastitu?

Ma kako različiti bili, svi proračuni jedinica lokalne samouprave imaju jednu zajedničku karakteristiku, a to je da su ograničeni. Ograničenje znači da je potrebno napraviti izbor. S jedne strane, logično je i opravdano da one jedinice koje ostaju u vlasništvu JLS i one čija će se vrijednost prije prodaje na taj način značajno povisiti. imaju prvenstvo. S druge strane, upravljanje lokalnom samoupravom više je od pukog maksimiziranja dobiti. Primjerice, ukoliko odluka o neulaganju se odrazi na propadanje nekih kulturnih dobara to će se u konačnici negativno odraziti na izgled i ugled grada, bez obzira na vlasništvo te imovine, što će opet rezultirati potencijalnim smanjenjem nekih prihoda. Potrebno je odrediti što su to izravne koristi za jedinicu lokalne samouprave i prema tome ravnati ulaganja u nekretnine. Ne treba ulagati tamo gdje je korist od toga nemjerljiva i/ili neizravna. Provođenjem financijske analize moguće je odrediti korist izdataka za ulaganje.

Nerijetko se ta pitanja odnose na sveukupnu politiku lokalne samouprave, te nikako nisu isključivo financijske naravi. Također, za jedinice lokalne samouprave potrebno je pratiti i sve izdatke koje bilježi za imovinu koja nije u njenom vlasništvu. Podaci o toj imovine daju korisnu informaciju donositeljima odluka.

Kada se donosi odluka o ulaganju i financijski pokazatelji su ključni, te je značajan proces u kojem se priprema i izrađuje proračun u što je uključeni indeksi odnosno analiza promjena prihoda i troškova.

Uzmimo za primjer ulaganje u sustav grijanja i toplinske izolacije. Takva investicija u praksi može opravdati višu cijenu najma jer je za najmoprimca omogućena niža cijena troškova grijanja te ušteda na tim troškovima za jedinicu lokalne samouprave to znači da kroz višu cijenu najma može vratiti tu investiciju zbog povećanja prihoda od najma, te je to situacija u kojoj sve strane imaju koristi.

- **Aktivnost 3.: Klasifikacija imovine**

Različite funkcije lokalne samouprave određene su Zakonom o lokalnoj i područnoj (regionalnoj) samoupravi. Zato su u Hrvatskoj portfelji često šaroliki te znaju sadržavati mnoge od nabrojanih kategorija u nastavku:

- zemljišta
- stanovi i kuće
- poslovni prostori za potrebe uprave
- poslovni prostori za zakup
- sportski objekti poput stadiona, dvorana itd.
- dječiji vrtići
- objekti kulturnih ustanova
- objekti za tržnice i održavanje sajmova
- objekti javne rasvjete
- industrijski objekti i skladišni prostori
- objekti komunalnih poduzeća
- groblja, objekti za uređenje prostora i održavanje čistoće
- ostali

Prije nego nastavimo ovu raspravu o klasifikaciji imovine, nužno je još jednom ponoviti neke od osnovnih pojmova. Ciljevi, kao i uloge JLS mogu biti tradicionalni i netradicionalni.. Uloga koju definiramo kao tradicionalnu podrazumijeva ponudu optimalnog broja jedinica imovine javnih dobara i usluga po cijeni koja je najniža kada ju usporedimo s pružateljima usluga iz javnog sektora.

Uloga koja se smatra netradicionalnom je ona koja ostvaruje prihod za jedinicu lokalne samoupravu iz alternativnih izvora te uključuje podršku lokalnom gospodarskom razvoju. Nezaustavljiv trend je da lokalna samouprava sve više prihvaća i koristi principe karakteristične za privatni sektor što znači da je fokus na povećanju imovine.

S ciljem uspješnog obavljanja svojih funkcija, naprednije jedinice lokalne samouprave usklađuju svoje djelovanje s glavnim globalnim trendovima kada je riječ o upravljanju imovine.

To su:

1. prebacivanje osiguranja nekretnina iz vlastitog aranžmana, te omogućavanje privatnom sektoru da osigura nekretnine;
2. nekretnine su produktivni resurs, i treba ih prestati promatrati kroz prizmu javnog dobra;
3. usvojiti i jačati praktične metode usmjerene prema učinkovitosti upravljanja po uzoru na javni sektor.

Funkcije lokalne samouprave sada uključuju „upravljanje stanovima, prostorno i urbanističko planiranje, komunalne usluge, brigu o djeci, socijalnu skrb, primarnu zdravstvenu zaštitu, primarno obrazovanje, kulturu, tjelesnu kulturu i sport, zaštitu potrošača, zaštitu i unapređivanje okoliša te vatrogastvo i civilnu zaštitu“.

Imovinu koja je potrebna za ispunjavanje istih dijeli se u 3 skupine:

A. obavezna imovina;
B. diskrecijska imovina
C. imovina za ostvarenje prihoda odnosno višak imovine

Efekt koji imovina za obvezne zadaće nosi može se optimalno odrediti povećanjem djelotvornosti namjene jedinica imovine, postavljanjem sustava na način da se zahtjeva od odjela jedinice lokalne samouprave da opravdaju svoju potražnju za tim konkretnim prostorima, smanjivanjem tekućih troškova na optimalnu mjeru, te odabirom lokacija ureda i onih u kojima se pružaju usluge lokalne samouprave u funkcionalne, skromnije objekte i manje atraktivna područja. Nastavno, vrlo je poželjno je izrađivati cost-benefit analize kojima se može opravdati namjena neke konkretne jedinice imovine u svrhu ispunjenja potreba lokalne samouprave.

Analizom stvarnih troškova moguće je optimizirati učinkovitost imovine za one zadaće koje se mogu nazivati diskrecijskim. Time se olakšava odabir najboljih mogućih odluka i stvaraju različite programske alternative kako bi kroz tu aktivnost postepeno smanjivali direktne, ali ii indirektne subvencije. Cilj jedinica lokalne samouprave treba biti postizanje da korisnici njihovih prostora samostalno obavljaju poslove održavanja imovine. Također, cilj je i motivirati korisnike da sami daju u podzakup dijelove prostora koje oni ne koriste. No, s druge strane važno je osigurati da se jedinicu lokalne samouprave kao vlasnika izvještava o tome

transparentno, pravovremeno i točno. Sljedeći korak je prilagoditi subvencije s ostvarenim prihodima.

Često se događa slučaj da jedinice lokalne samouprave na raspolaganju imaju previše imovine koje su namijenile za obavljanje obveznih funkcija istih. Primjerice, moguće je da gradski uredi uopće ne zauzimanju sav prostor kojima raspolažu u zgradama u vlasništvu grada. U tom smislu, postojeći višak prostora smatra se prostorom koji potencijalno ostvaruje prihod odnosno diskrecijski prostor.

Stoga, taj višak imovine koji se ne koristi za obavljanje osnovnih funkcija jedinicama lokalne samouprave služi kao dodatni izvor prihoda. Takve nekretnine odnosno dijelove nekretnina je optimalno dati u zakup zakupodavcu koji ponudi najvišu cijenu koja zadovoljava minimalna očekivanja lokalne samouprave, te svojim aktima osigurati korištenje prostora za namjenu koja je najprikladnija. Povremeno treba prihode ostvarene na opisani način usporediti s alternativnim mogućnostima poput prodaje. Također, nužno je raditi analize isplativosti ulaganja u tu kategoriju nekretnina te provoditi selektivna kapitalna ulaganja te tako povećati prihoda koje ostvaruje. Druga opcija je iskoristiti podizanje vrijednosti uzrokovano investicijom, te ih prodati kako bi ostvarili veći jednokratni prihod.

- **Aktivnost 4.: Procjena nekretnina**

Priručnik (Bertović, 2004.) jedinicama lokalne samouprave vezano uz procjenu nekretnina preporuča:

- Izabrati one nekretnine koje se smatraju prenosivim (trenutno i potencijalno) i obaviti procjenu njihove realne tržišne vrijednosti.
- Sustavna promjena započinje tako da se prvo procijeni nekoliko jedinica imovine. Navedene jedinice trebale bi biti ili potencijalno najunosnije ili najproblematičnije.
- Prodaji imovine jedinice lokalne samouprave mora prethoditi neovisna procjena.
- Sve upravitelje imovinom nužno je obučiti za odrađivanje stručne procjene na način da u odnosu na profesionalne procjenitelje oni budu dobro educirani klijenti.

- Nužno je procjenom odrediti troškove vijeka trajanja neprenosive imovine.

Postoje dvije skupine imovina: prenosiva i neprenosiva. Prenosiva imovina je najveća i ona uključuje jedinice imovine koje se potencijalno mogu prodati. Neprenosiva imovina sadrži imovinu poput mostova, cesta i sličnih infrastrukturnih jedinica imovina . Za prvu skupinu je ključ praćenja i kontrole rezultata poznavanje tržišne vrijednosti imovine, dok se za drugu skupinu koristi suvremeni pristup procjene nazvan cijena vijeka trajanja. Cijena vijeka trajanja je zbroj cijene izgradnje, cijene troškova održavanja i popravaka za cjelokupno vrijeme trajanja te jedinice imovine.

Kada upravitelj nekretninom želi donijeti racionalnu odluku računovodstvena i knjigovodstvena vrijednost ima malo i ograničeno značenje. U suštini računovodstvene vrijednosti su izračun koji se temelji na ostvarenoj cijeni kupnje, dakle na temelju povijesnog troška te se umanjuju za amortizaciju koja se izračunava po formuli. Računovodstvena vrijednost bila bi relevantnija za donositelje odluka kada bi uključivala i povremenu prilagodbu početnih troškova izgradnje stopi inflacije. Svakako, računovodstvena vrijednost imovine, rijetko kad je povezana s trenutačnom tržišnom vrijednosti. Također, ona ne predstavlja niti cijenu vijeka trajanja.

U današnjoj praksi najzastupljenije su tri metode odnosno pristupa procjeni tržišne vrijednosti (Bertović, 2004.):

1. **Pristup troška**, vrijednost = *tržišna vrijednost zemljišta + procjena troškova građenja*
2. **Pristup usporedbe prodaja**. Predstavlja usporedbu sličnih jedinica imovine čija je kupoprodaja realizirana na tržištu.
3. **Pristup kapitalizacije dohotka**. *vrijednost = tijek novca / očekivana stopa povrata.*

Naravno, uvijek je procjena koja ima temelj u više pristupa relevantnija i vjerodostojnija. Ipak, valja naglasiti kako je procjena vrijednosti samo procjena, dok se vrijednost određuje na tržištu u kupoprodajnom procesu koji je kupoprodajna interakcija između kupca i prodavatelja.

Pitanje procjene vrijednosti imovine lokalne samouprave jest najvažnije metodološko pitanje. Postoji razlika između shvaćanja pojma vrijednosti u praksi jedinica lokalne samouprave i onog kako je pojam shvaćen u međunarodnoj praksi i unutar privatnoga sektora u Hrvatskoj. Pojedine lokalne samouprave koriste se nekim nestandardnim definicijama, što kao rezultat daje podcjenjivanje vrijednosti nekretnina lokalne samouprave.

Važno je pravilno koristiti politiku korištenja profesionalne stručnosti, ali i unapređivanja vlastitih ljudskih resursa za procjenu imovine te jedinice lokalne samouprave. To se sastoji od više elemenata. Prije svega, potrebno je osposobiti zaposlenike jedinica lokalne samouprave o upravljanju imovinom s naglaskom na procjeni imovine. Također, upravitelji imovinom u svrhu preliminarne analize trebaju moći pravilno pretpostaviti koja je vrijednost imovine kojom upravljaju.

Nakon uključivanja profesionalaca, njih treba zapošljavati isključivo na temelju javnog natječaja. S ciljem odabira najkvalificiranijih kadrova preporuča se provoditi predkvalifikacijske ocjenjivačke postupke. Valja naglasiti i kako će uvijek više od jednog procjenitelja za procjenu vrijednosti nekretnina bolje usporediti kvalitetu izvješća o procjeni i procijenjenim vrijednostima te je to smjer u kojem treba razmišljati pri njihovom angažmanu.

S obzirom na visoke troškove, nužno je pratiti da cijena procjene ne treba biti viša od očekivanih koristi iste. U nekim slučajevima poput sudskih postupaka, kada se nekretnina koristi kao jamstvo, i pri raspolaganju imovinom bez otvorenog natječaja obavezno je izraditi procjenu vrijednosti. U nekim slučajevima, gdje je moguć gore navedeni slučaj gdje cijena procjene može biti viša od očekivanih koristi, prije no što se krene s procjenom, stručni upravitelji imovinom jedinice lokalne samouprave trebali bi načiniti preliminarnu analizu. Na temelju takvih analiza određuje se kojoj jedinici imovine je veći prioritet potrebe za procjenom vrijednosti.

Preporuča se i izrada nove procjene za svaku nekretninu svakih pet godina, a kako bi te procjene bile objektivnije isti procjenitelj ne bi trebao stalno procjenjivati istu nekretninu, nego ih je potrebno rotirati. Također, treba izbjeći određenu vrstu monopola procjena u kojoj isti procjenitelj procjenjuje sve nekretnine u portfelju.

- **Aktivnost 5.: Operativni izvještaji za imovinu i portfelje**

Ova aktivnost glavni fokus stavlja na sustavnu upotrebu operativnih izvještaja za svu imovinu, što uključuje i nekretnine. U njih je nužno uključiti sve prihode i rashode za svaku jedinicu imovine, te staviti poseban naglasak na vrlo važnu stavku a to su troškovi upravljanja. Kako bi se ova aktivnost efikasno provodila „treba upotrebljavati računalne aplikacije za upravljanje imovinom, i to posebno one aplikacije koje se mogu nabaviti u Hrvatskoj i za koje se može dobiti podrška u privatnim organizacijama za upravljanje imovinom i njihovim podružnicama“. (Bertović, 2004.)

Za svaku jedinicu imovine potrebno je pripremiti godišnji proračun odnosno financijski plan, te provoditi vezane aktivnosti poput analize stvarnih i planiranih učinaka imovine. Tako se mogu identificirati problematične jedinice.

U mnogo jedinica lokalne samouprave u RH se podaci o financijskim rezultatima ne prikupljaju na temelju pojedinačne imovine, nego se to čini zbrojno, što je neprikladno za upravljanje imovinom.

- **Aktivnost 6.: Intenzivna financijska analiza portfelja, imovine i projekata**

Kao što je raspravljeno prethodno u disertaciji, imovinski portfelji jedinica lokalnih samouprava mogu biti jako različiti i to prema sadržaju, značaju i veličini. Također, pojedine lokalne samouprave provode projekte, a značajan broj uključuje razvoj neke nekretnine. Ponekad je više od polovice proračuna lokalnih samouprava namijenjeno za izdatke vezane za razvoj i održavanje nekretnina. (Bertović, 2004.) Razvidno je da tolika raznolikost portfelja i projekata zahtjeva pažljivo praćenje i nadzor što osigurava izbjegavanje financijskih gubitaka i propadanje imovine. Osnovno sredstvo za ostvarenje ciljeva upravljanja je studija izvedivosti koja uključuje analizu očekivanih financijskih posljedica prije započinjanja projekta. Oblici i forma takvih studija su različiti, ovisno o projektu.

Ako želi konsolidirati osnovne podatke o prihodima i izdacima za svaku jedinicu imovine jedinica lokalne samouprave treba uvesti računovodstvo na razini imovine. Tada će jedinica lokalne samouprave imati značajne koristi od spoznaja poput koliki je neto prihod odnosno

novčani tijek od imovine. Za imovinu koja je izložena izdacima, ali ne stvara prihode imat izvješća će pokazati detalje gubitaka koje trpi. Na primjer, upotreba zgrade koja se koristi kao gradska vijećnica ima negativan tijek gotovine iz razloga što ne ostvaruje prihode potrebne za plaćanje operativnih troškova zgrade. U konačnici, jedinica lokalne samouprave je izložena financiranju troška funkcioniranja te zgrade. To bi bilo vidljivo na imovinskom financijskom izvještaju kao jedini trošak. Detalji funkcioniranja zgrade u tom slučaju vide se u operativnom izvještaju za imovinu. Time se omogućuje detaljan izvještaj i konkretnu analizu svih troškova funkcioniranja gradske vijećnice na jednome mjestu.

- **Aktivnost 7.: Deregulacija poslovnih zakupa i poboljšanja cijena zakupa**

Sadašnju politiku i praksu zakupa poslovnih prostora u lokalnim samoupravama u Hrvatskoj nije usklađena s uobičajenim pristupima u zemljama s razvijenim tržišnim gospodarstvima.

Upravljanje nekretninama u lokalnim samoupravama u Hrvatskoj izgleda prekomjerno reguliran, s uglavnom negativnim posljedicama za gospodarstvo lokalne samouprave. Prekomjerna se regulacija događa na nekoliko načina. Lokalne samouprave definiraju vrstu upotrebe imovine u previše detalja. Stoga, kad je imovina ponuđena na natječaj, ona ima svoju dopuštenu upotrebu propisanu preusko.

U gradovima s tržišnim gospodarstvom, odluke treba li otvoriti trgovinu, ugostiteljski prostor, bilo kakvu drugu svakodnevnu ili specijaliziranu uslugu ili čak ured na nekoj konkretnoj lokaciji ostavljene su privatnim poduzetnicima koji pružaju sve te usluge i međusobno se natječu za dobivanje prostorija na konkretnim lokacijama, zasnovanim na signalima potražnje. Urbanistički planovi postavljaju općenita ograničenja upotrebe, ali unutar tih ograničenja nalazi se široka fleksibilnost koja omogućava, na primjer, prodaju odjeće, restoran, elektronički servis ili frizerski salon u prostoru ”trgovine“. Mnogo je puta u svijetu dokazano da prodavači u privatnom sektoru imaju bolji osjećaj što bi ljudi mogli trebati na konkretnoj lokaciji, nego što bi bilo koja samouprava mogla imati. Kad samouprava odluči kako bi se trebala upotrebljavati jedinica nekretnine, time stvara umjetne prostorne okvire koji iskrivljuju tržišta. U lokalnim su samoupravama u Hrvatskoj iskrivljenja koja rezultiraju iz takvih planskih alokacija nekretnina značajna. Također, bilo kakva dodatna ograničenja nametnuta na korištenje imovine smanjuju potencijalni prihod a s time i vrijednost imovine, do čega vlasnik može doći kroz zakup ili

prodaju imovine. Dalje, ta ograničenja gravitiraju prema povećanju vremena kada je prostor prazan i vode propadanju stanja i izgleda imovine i okolnog područja.

Kritična područja poboljšanja rezultata upravljanja imovinom od strane lokalnih samouprava u Hrvatskoj uključuju poboljšanje postupaka davanja u zakup i ugovora, povećanje stope ubiranja zakupnine i smanjenje operativnih troškova i troškova upravljanja. Kapitalni izdaci za poboljšanje energijske efikasnosti, na primjer, mogu smanjiti operativne izdatke ili povećati zakupninu koju su korisnici voljni platiti, ili oboje.

- **Aktivnost 8.: Kvantificiranje i praćenje direktnih i indirektnih subvencija u vezi s nekretninama, koje dobivaju zakupci i korisnici nekretnina u vlasništvu lokalne samouprave**

Najbolja namjena imovine je ona koja osigurava najvišu najamninu i vrijednost za vlasnika. To se može ostvariti kada jedinica lokalne samouprave u zakup daje nekretninu za najpoželjniju namjenu prema potražnji na tržištu. Naravno, uvijek je nužno uzeti u obzir ograničenja uređenja prostora. Ako poduzeće zaista uspješno odredi potražnju za dobrima i uslugama koje pruža na toj konkretnoj lokaciji to dovodi do većeg prometa i dobiti za poduzeće iz čega se mogu pokrivati troškovi veće najamnine. Stoga, možemo zaključiti da najbolja namjena imovine osigurava najvišu najamninu, a samim time i vrijednost za vlasnika.

U slučajevima koji su učestali u RH u kojima čelnici jedinica lokalnih samouprava propuštaju ostvariti veći dohodak za proračune lokalnih samouprava iznajmljivanjem imovine ispod tržišne cijene ta razlika realno predstavlja indirektne subvencije u vezi s imovinom.

Ako ne postoji sustav preciznog praćenja i izvještavanja nemoguće je procijeniti ukupan iznos propuštenoga dohotka. U nekim slučajevima, cijena najma imovine lokalne samouprave može biti čak dvostruko viša od trenutne. Na primjerima neprofitnih organizacija vidljiv je primjer indirektnih subvencija. Neprofitnim organizacijama se u najam daju prostori po simboličnoj zakupnini, vrlo često smješteni u najatraktivnijim i najskupljim zonama, povijesnim ili poslovnim središtima. Takva simbolična zakupnina koju plaćaju može biti desetak puta niža od one tržišne. Takve odluke lokalne samouprave uvijek su isključivo političke naravi. Donositelji odluka bi trebali bi biti dobro informirani o troškovima takvih indirektnih subvencija. Ukoliko

se za svaku jedinicu imovine zasebno zna koliko je procijenjeni tržišni najam, iznos subvencije može se procijeniti kroz formulu:

Indirektna subvencija najma = Tržišna najamnina - Stvarni najam

- **Aktivnost 9.: Izvještavanje o imovini**

Potpune i jezgrovite informacije o imovini koju lokalna samouprava posjeduje i/ili podupire nisu potrebne samo lokalnoj samoupravi nego i njenim stanovnicima. Gradonačelnicima, vijećnicima i stanovnicima nisu nužno potrebne toliko detaljne informacije o svakoj jedinici imovine. Oni bi trebali imati sažet prikaz u koji su uključeni glavni portfelji imovine, te prihode i rashode glavnih institucija uključenih u njih. Potrebno je postići zadovoljavajuću razinu informiranosti kako bi javnosti mogli konkretno prikazati na koji način se upravlja tom imovinom. Takvo izvještavanje otklanja sumnju u korupciju u raspodjeli imovine, te podiže transparentnost jedinice lokalne samouprave.

Zasada jedinice lokalne samouprave nemaju usklađen i standardiziran oblik izvještavanja, što se preporuča. Taj izvještaj mora nuditi dovoljnu količinu informacija kojima se zadovoljava potreba građana za informiranošću i praćenju rada lokalne samouprave. Koliko je javnih dobara i usluga, uključujući rad, utrošeno na održavanje imovine u vlasništvu grada u zamjenu za manji najam? Potrebno je odrediti vrijednost razmjene tih dobara ili usluga u cilju potpune analize troška vlasništva nad imovinom, uključujući i trošak održavanja.

U slučaju kada se imovina u vlasništvu jedinice lokalne samouprave iznajmljuje po tržišnim cijenama, manje je važno znati detalje o njihovu održavanju, osim onih informacija koje su potrebne za provjeru poštivanja ugovornih uvjeta. U slučaju kada korisnik prima indirektnu subvenciju kroz najam imovine nužno je da vlasnika pravodobno i detaljno izvještava o financijskim informacijama, koje uključuju i troškove održavanja imovine, te isto tako i ostvarene prihode iz tog izvora. (Bertović, 2004.)

- **Aktivnost 10.: Konsolidiranje upravljanja**

Gotovo uvijek funkcija upravljanja imovinom podijeljena je u između nekoliko upravnih tijela. Stoga je čest slučaj da niti jedno od tih tijela nema cjelovit uvid u situaciju. Organizacijska

poboljšanja u upravljanju imovinom u Hrvatskoj su moguća na najmanje na dva načina. Prvo, potrebno je organizirati središnji ured za upravljanje imovinom. Takav ured bio bi odgovoran za izradu i primjenu strategije, te nastavno na strategiju i programa sa konkretnim aktivnostima vezanim uz upravljanje imovinom. Naravno, jedna od osnovnih zadaća tog ureda bilo bi organiziranje prikupljanja potrebnih informacija koje služe za racionalno upravljanje imovinom. Nadalje, pod ingerencijom istog ureda trebaju biti planovi poboljšanja financijskog stanja pojedinačnih jedinica imovine i portfelja o čemu bi redovito trebali pripremati izvješća. Drugi način je racionalno angažiranje vanjskih dobavljača. Uobičajena je praksa da se određen broj zadataka vezan uz funkciju upravljanja imovinom ustupi vanjskim organizacijama. Takav angažman može uključivati cjelovite zadatke poput upravljanja konkretnom nekretninom, te njeno održavanje ili može uključivati upravljanjem čitavim portfeljem, također angažman može ići i u smjeru obavljanja specijaliziranih funkcija poput računovodstvene. Bitno je da korištenje vanjskih organizacija bude transparentno uz potpunu odgovornost izvođača za rezultate. Nikada nije dovoljno naglašavati značaj centraliziranja odgovornosti u upravljanju imovine. Jedan ured treba imati potpunu odgovornost i nadležnost. Odgovornost znači da su odgovorni za sve aspekte financijskih rezultata imovine jedinice lokalne samouprave, ali isto tako i za očuvanje i povećanje vrijednosti portfelja imovine lokalne samouprave. Oni trebaju biti ovlašteni za delegiranje različitih potrebnih zadataka drugima, te za provedbu uvjeta ugovora s dobavljačima.

Također, vrsta kontrole koja je centralizirana pruža bolje komunikacijske mogućnosti. Na primjer, ako postoji problem s prikupljanjem najamnine, to može predstavljati poveznicu s nedostatnim održavanjem i popravcima na konkretnoj iznajmljenoj jedinici imovine. Moguće je da korisnik ne plaća zakup jer ima problem s vlagom. Zadatak je upravitelja osigurati naplatu, makar prisilnim putem, ali i sanirati štetu nastalu zbog problema s vlagom. (Bertović, 2004.)

3.4. Utjecaj upravljanja nekretninama na gospodarski razvoj i na financijski položaj gradova

Koncentracija moći, razvojnih sposobnosti i utjecaja kojeg veliki gradovi imaju oduvijek izazivaju interes znanstvenika iz polja ekonomije i financija, ali i mnogo šireg kruga ljudi koji razmišljaju i raspravljaju o ovoj temi. Lokalni proračuni, a poseban značaj među njima imaju oni gradski, imaju izrazitu razvoju ulogu. U mnogim radovima posvećenim lokalnoj

samoupravi naglašen je interes za položaj i ulogu gradova u suvremenom društvu. Jedan od razloga za takav interes definitivno je vezan uz značaj procesa urbanizacije.

Dvadeseto stoljeće je svakako i nedvojbeno stoljeće urbanizacije. Tu tvrdnju lako je poduprijeti kroz nekoliko činjenica u nastavku. Svijet s početku dvadesetog stoljeća imao je samo šesnaest gradova koji su imali više od milijun stanovnika. Među njima najveći je bio London koji je brojao oko sedam milijuna stanovnika. Svijet na početku 21. stoljeća imao je više od 500 gradova s više od milijun stanovnika. Na početku 19. stoljeća u ruralnim područjima živjelo je 97% ukupnog stanovništva dok je u gradovima živjelo svega 3%. Taj broj je rastao na 14% na početku 20. stoljeća, a početkom 21. stoljeća približno 50%. stanovništva živi u gradovima. (Harvey, 2001.)

Značajna godina u ovom smislu bila 2007. iz razloga što je te godine je UN prvi puta u povijesti čovječanstva zabilježio da u gradovima živi više stanovnika nego u ruralnim krajevima. Većinski udio stanovništva koji živi u gradovima je na globalnoj razini sasvim nova pojava. Taj proces svakako ima utjecaj ili u najmanju ruku može imati utjecaj i na funkcioniranje lokalne samouprave.

Ubrzan rast gradskog stanovništva u kombinaciji s ograničenim proračunskim sredstvima za financiranje infrastrukture dovodi do svojevrsnog infrastrukturnog deficita što rezultira substandardnom uslugom koju gradovi pružaju svojim stanovnicima Ta pojava je dodatni pritisak na gradske vlasti. (Rogić Lugarić, 2010.)

Neke današnje velike metropole su toliko značajne da je njihov utjecaj jak čak i na globalnoj razini. Moderni gradovi su presudni za uspjeh nove ekonomije, glavni razvojni akteri, pokretači društvenog razvoja. Grad je u svakom slučaju važno uporište modernizacije. Teza o tome da su gradovi ključni za uspjeh nove ekonomije ima uporište u prethodnim raspravama (Jacobs, 2007): „Korist od gradova je u tome da oni osiguravaju okruženje, ozračje, kontekst u kojima se inputi – pronicljivost i prilagodljivost – mogu uspješno ubrizgavati u svakodnevni gospodarski život ... Društva u kojima gradovi zamru više se ne razvijaju i bogate. Ona propadaju“. (Rogić Lugarić, 2010.)

- Primjer Grada Rijeke

Smješten uz Kvarnerski zaljev, izazov Grada Rijeke vezan je uz ograničenja kopnenog područja.

Prema strateškom dokumentu Razvojna strategija Grada Rijeke 2014.-2020., Rijeka se prostire na otprilike13.600 ha. Kopneni dio je puno manje te iznosi 4.355 ha. Prostor kojim Grad Rijeka raspolaže nije dovoljan za zadovoljenje razvojnih potencijala grada. U Rijeci prema zadnjem popisu stanovništva živi 128.624 stanovnika (DZS, 2011.). Kada pogledamo podatke o gustoći naseljenosti u RH i šire vidimo da je to jedna od najvećih gustoća naseljenosti u ovom dijelu Europe (2.923 stanovnika/km²). Prema posljednjem popisu stanovništva Državnog zavoda za statistiku RH ima 4.290.612 stanovnika. Od toga njih čak 3.016.137 živi u 127 gradova. Prvi po broju stanovnika je Zagreb, drugi grad u Hrvatskoj je Split,. Rijeka je treći grad u Hrvatskoj po broju stanovnika, a na četvrtom mjestu se nalazi Osijek.

Županije u kojoj se Rijeka nalazi, Primorsko-goranska županija ima 296.123 stanovnika, dok gustoća naseljenosti iznosi 82,55 stanovnika/km2. Ne postoje stručne analize koje odgovaraju na pitanje koji je optimalan broj stanovnika za gradove ove veličine i sličnih karakteristika.

Grad Rijeka obzirom na svoje gospodarske kapacitete je stvarno središte Primorsko-goranske županije u kojoj živi 296.123 stanovnika. To se može dokazati promatramo li dio Rijeke u ukupnom broju zaposlenih. Udio radno aktivnog stanovništva Grada Rijeke u Primorsko-goranskoj županiji iznosi 58%, a udio u ukupnom broju stanovnika PGŽ-a značajno manje, 43,5%.

Također, Rijeka je značajan grad i u kulturnom, zdravstvenom te u sveučilišnom smislu. Stoga, gradu gravitiraju i stanovnici Istarske i Ličko-senjske županije. Također, Rijeka ima utjecaj i na pogranično područje s Republikom Slovenijom. Zaključno, ispravna je teza da je Rijeka središte zapadne Hrvatske iz čega proizlazi činjenica da su njena ulaganja u prometnu i komunalnu infrastrukturu usmjerena na područje koje je mnogo veće od granica same Rijeke.

Smatrati da svaka jedinica lokalne samouprave treba osnaživati vlastitu konkurentnost nije netočno, ipak valja spomenuti da trenutni zakonski okvir omogućava neke oblike interesnog udruživanja više jedinica lokalne samouprave.

U Zakonu o lokalnoj i područnoj (regionalnoj) samoupravi veliki grad se definira kao „jedinicu lokalne samouprave koja je ujedno gospodarsko, financijsko, kulturno, zdravstveno, prometno i znanstveno središte razvitka šireg okruženja i ima više od 35.000 stanovnika“.

Grad Rijeka je sukladno zakonskoj definiciji veliki grad. Zbog toga u svome djelokrugu rada obavlja zadaće od lokalnog značenja, njima se izravno zadovoljavaju potrebe građana. Riječ je o poslovima, kako ih Zakon definira, koji se odnose na prostorno i urbanističko planiranje, zaštitu prirode i okoliša, uređenje naselja i stanovanje, komunalno gospodarstvo, kulturu, primarnu zdravstvenu zaštitu, brigu o djeci, socijalnu skrb, odgoj i obrazovanje, tjelesnu kulturu i sport, zaštitu potrošača, protupožarnu i civilnu zaštitu, promet, održavanje javnih cesta, izdavanje građevinskih i lokacijskih dozvola i ostale poslove sukladno posebnim zakonima.

Jedan od najvažnijih segmenata je fiskalna decentralizacija koja mora biti usklađena s decentralizacijom ovlasti odnosno funkcijskom decentralizacijom. U Hrvatskoj je visok stupanj centralizacije što se najbolje može vidjeti na primjeru raspodjele ovlasti za utvrđivanje poreznih prihoda. Sustav je takav da središnja vlast u potpunosti samostalno određuje stope zajedničkih i županijskih poreza, a stope općinskih i gradskih poreza djelomično utvrđuje lokalna vlast uz stroga ograničenja određena od strane središnje vlasti. Iz tog proizlazi da ne postoji puna autonomija u odlučivanju. Posljedično, u proračunima lokalne samouprave više od 50% prihoda odnosi se na prihode na čiju visinu jedinice lokalne samouprave nemaju utjecaj, a mogu utjecati tek na 20% ukupnih prihoda.

Grad Rijeka je u svojoj evidenciji na koncu 2012. godine kao svoje vlasništvo bilježi:

- 26 kulturnih objekata
- 24 prostora vrtića
- 20 osnovnih škola
- 11 srednjih škola
- 30 zdravstvenih objekata
- 72 sportska objekta i objekta tehničke kulture
- 11 objekata i prostora socijalne skrbi
- 27 prostora vijeća mjesnih odbora.
- groblja, komunalna infrastruktura, 20 fontana te 1.525.497 m² zelenih površina, s 285 dječja igrališta i ostalom imovinom

- 2.032 stana
- 1.739 poslovni prostor
- 7.539 zemljišnih čestica ukupne površine 6.197.974,89 m² (Grad Rijeka, 2014.).

Neki važni gradski kapitalni projekti realizirani su uz pomoć kredita. Kredit će se u potpunosti otplatiti do kraja 2013. godine. Grad Rijeka se financira i putem municipalnih obveznica koje su izdavali u periodu od 2006. do 2008. godine. Tim sredstvima financirana je izgradnja kompleksa Dvoranskog plivališta koje se nalazi na Kantridi. Municipalne obveznice se isplaćuju od 2010. godine i otplaćivat će se do 2016. godine. (Grad Rijeka, 2014.)

U Strategiji se navode i tri robna zajma što nije klasično zaduživanje. Riječ je o preuzimanju stanova, prometnica i sportskih objekata, koje su izgradili Agencija za društveno poticanu stanogradnju Grada Rijeke, TD *Rijeka promet* d.d. i TD *Rijeka sport* d.o.o. Grad Rijeka ih prenosi u svoje vlasništvu, time povećava svoju imovinu, ali i preuzima dug. Rijeka je na taj način riješila pitanje dijela socijalno najugroženijih sugrađana, poboljšala uvjete za sportske aktivnosti, te je proširena prometna mreža.

Potencijali daljnjeg razvoja lokalne samouprave u Hrvatskoj postoji i ima velike potencijale. Nužno je nastaviti decentralizaciju i jačanje uloge lokalne samouprave. Lokalnoj samoupravi, a posebice velikim gradovima treba omogućiti snažniji utjecaj na razvoj lokalnoga gospodarstva.

3.5. Revizija učinkovitosti – upravljanje i raspolaganje nekretninama lokalne i područne samouprave

Na temelju Zakona o lokalnoj i područnoj (regionalnoj) samoupravi (NN, br. 33/01, 60/01, 129/05, 109/07, 125/08, 36/09, 150/11, 144/12, 19/13 - pročišćeni tekst i 137/15) „jedinice lokalne i područne (regionalne) samouprave koriste, upravljaju i raspolažu pokretnim i nepokretnim stvarima koje, uz imovinska prava, sačinjavaju njihovu imovinu“. Prema istom Zakonu, oni su dužni „imovinom upravljati, koristiti se i raspolagati pažnjom dobrog gospodara“. Iz navedenog je razvidno da imovina u njihovom vlasništvu mora biti stavljena u funkciju obavljanja poslova iz njihovog djelokruga, ali također ima za cilj i kreiranje nove vrijednosti i ekonomske koristi.

Državni ured za reviziju je izvršio reviziju učinkovitosti upravljanja raspolaganja nekretninama jedinica lokalne i područne (regionalne) samouprave u razdoblju od 23. veljače 2015. do 18. siječnja 2016.

U nalazima predmetne revizije učinkovitosti je utvrđen niz nepravilnosti i propusta. Navedeni propusti uzrokovani su različitim djelovanjima na poljima evidentiranja, popisivanja i ostalim aktivnostima. Također, utvrđene su i nepravilnosti uzrokovane zakupom, nabavom i prodajom imovine. U Hrvatskom saboru je Državni ured za reviziju u ožujku 2016. dostavio Izvješće o obavljenoj reviziji upravljanja i raspolaganja nekretninama jedinica lokalne i područne (regionalne) samouprave. Dostavljeno je jedno skupno izvješće te pojedinačna izvješća o obavljenoj reviziji za 20 Županija, i Grad Zagreb koji ima posebni status.

Reviziju se smatra cjelovitom jer su njome obuhvaćene sve jedinice lokalne samouprave u RH (20 županija, 127 gradova, 423 općina i Grad Zagreb). Predmet revizije bila je upravljanje nekretninama. Poseban naglasak Izvješće stavlja na građevinska zemljišta, stanove i poslovne prostore odnosno građevinske objekte. Valja naglasiti i kako su neka djelovanja posebno razmatrana, to se odnosi na sustav kontrola upravljanja i raspolaganja nekretninama, te uređenje i usklađenost upravljanja i raspolaganja nekretninama sa zakonima.

Razdoblje koje revizija obuhvaća je od 2012. do 2014., no iznimno su obuhvaćena i kasnija i ranija razdoblja.

Ciljevi postupka revizije bili su (DUR, 2016.):

- Ocjenjivanje cjelovitosti podataka o nekretninama.
- Utvrđivanje normativnog uređenja
- Provjeriti usklađenost s propisima
- Ocijeniti učinkovitost sustava unutarnjih kontrola

Revizija je zabilježila da krajem 2014. godine jedinice lokalne samouprave upravljaju i raspolažu s:

- građevinskim zemljištem ukupne površine 338.174.458 m2
- 22.425 poslovnih prostora ukupne površine 3.613.956 m2
- 18.371 stanom površine 933.762 m2

Raspolažući navedenom imovinom u promatranom razdoblju, jedinice lokalne samouprave ostvarile su ukupne prihode na razini 2.811.466.915,00 kuna.

Temeljno pitanje na koje ova revizija traži odgovore jesu li jedinice lokalne samouprave raspolagali i upravljali svojim nekretninama učinkovito. To je razrađeno kroz četiri pitanja o (DUR, 2016.):

1. Cjelovitosti podataka o nekretninama
2. Normativnom uređenju upravljanja i raspolaganja nekretninama
3. Raspolaganjem svojim nekretninama pažnjom dobrog gospodara
4. Efikasnosti sustava unutarnjih kontrola

Na temelju ovih pitanja Državni ured za reviziju definirao je ocijenio je učinkovitost raspolaganja i upravljanja nekretninama. Sukladno navedenom , da se upravljanje i raspolaganje nekretninama ocjeni učinkovito od strane DUR-a, općine, gradovi i županije moraju (DUR, 2016.):

- Imati cjelovite podatke o nekretninama, odnosno poduzimati sve potrebne aktivnosti radi utvrđivanja cjelovitih podataka o nekretninama
- Normativno urediti upravljanje i raspolaganje nekretninama
- Nekretninama upravljati i raspolagati pažnjom dobrog gospodara
- Uspostaviti učinkovit sustav unutarnjih kontrola.

Djelomično učinkovitim DUR ocjenjuje upravljanje i raspolaganje nekretninama kada su u upravljanju i raspolaganju nekretninama potrebna određena poboljšanja, kada aktivnosti vezane uz sveobuhvatnost podataka o nekretninama nisu dovoljne te kada je samo djelomično normativno uređeno upravljanje nekretninama. U slučaju kada su potrebna veća i značajna poboljšanja, upravljanje i raspolaganje ocjenjuje se neučinkovitim. Istu ocjenu dobivaju jedinice lokalne samouprave koje nisu poduzele mjere za utvrđivanje cjelovitih podataka o nekretninama i kada upravljanje nekretninama nije normativno uređeno.

U postupku revizije ispitana je primjena zakona i akata lokalnih jedinica, provjerene su poslovne knjige i knjigovodstvene isprave. Također, obavljeni su razgovori s odgovornim osobama, analizirani su prikupljeni pisani upitnici, te su zatražena obrazloženja nekih poslovnih događaja. U okviru provedbe revizije učinkovitosti utvrđeno je kako je obavljanje poslova u vezi s upravljanjem i raspolaganjem nekretninama u općinama, gradovima i županijama organizirano na različite načine i uvelike ovisi o veličini jedinice, ali i o nekim drugim faktorima

poput broja zaposlenih ili o unutarnjem ustrojstvu. U većini jedinica lokalne samouprave poslove upravljanja nekretninama izvršavaju zaposlenici uz druge poslove iz djelokruga lokalne samouprave. U onim jedinicama koje imaju više upravnih tijela poslovi upravljanja nekretninama u nadležnosti su više odjela. U nekim jedinicama je ustrojen zasebni odjel ili odsjek unutar odjela za obavljanje ovih poslova.

DUR naglašava da je potrebno prilagoditi unutarnje ustrojstvo s ciljem bolje koordinacije tih poslova kada je slučaj da se izvršavaju u više odjela. Posebno kada je nužno provoditi procedure, razmjenjivati dokumentaciju i usklađivati podatke.

Prema podacima DUR-a ukupna vrijednost nefinancijske imovine svih jedinica lokalne samouprave na kraju 2014. godine iznosi 86.268.356.225 kuna (DUR,2016.).

Mišljenje DUR-a vezano uz temu evidencija o nekretninama je da (DUR, 2016.):

- Sve nekretnine moraju biti evidentirane u poslovnim knjigama jedinica lokalne samouprave
- Nekretnine je obavezno evidentirati prema vrsti, količini i vrijednosti
- Poslovne promjene u vezane uz nekretnine moraju biti transparentno evidentirane
- Nekretnine je obavezno obuhvatiti godišnjim popisom imovine
- Podaci u poslovnim knjigama obavezno moraju biti u skladu s podacima utvrđenim popisom imovine
- Obavezno je ustrojiti registar imovine u kojem su sadržani podaci i informacije potrebne za registar državne imovine

DUR u Izvješću ističe sljedeće preporuke vezane uz upis nekretnina u zemljišnim knjigama i katastru:

- Potrebno je organizirati radionice i izrađivati vodiče o podnošenju zahtjeva za dodjelom imovine, odnosno na druge načine razvijati suradnju između jedinica lokalne samouprave i Državnog ureda za upravljanje državnom imovinom
- Potrebno je poduzeti mjere kojima će se utvrditi stvarno stanje imovine u skladu sa zakonima
- Nužno je evidentirati imovinu u poslovnim knjigama.

- U financijskim izvještajima nužno je iskazati svu imovinu za koju su riješeni imovinskopravni odnosi Za ostalu imovinu predlaže se poduzimati mjere za njihovo rješavanje
- Upisivati prava vlasništva u korist jedinica u zemljišnim knjigama
- Pokrenuti proces usklađivanja podataka u katastru i zemljišnim knjigama
- U poslovnim knjigama obavezno je evidentirati sve poslovne promjene u vezi s nekretninama
- Nužno je uskladiti podatke u glavnoj knjizi i analitičkoj evidenciji
- Voditi registar imovine jedinice lokalne samouprave
- Potrebno je izraditi plan aktivnosti za rješavanje imovinsko-pravnih odnosa

Najvažnije preporuke DUR-a o normativnom uređenju jedinicama su (Zorić, 2016.; DUR, 2016):

- Strategijom je potrebno odrediti ciljeve i smjernice upravljanja i raspolaganja nekretninama, uzimajući u obzir gospodarske i razvojne interese lokalne jedinice
- Za sve oblike upravljanja i raspolaganja nekretninama planirane strateškim dokumentima potrebno je urediti ovlasti, procedure i kriterije
- Jedinica lokalne samouprave, zbog utvrđivanja jednakih pravila postupanja, treba svojim unutarnjim aktima urediti pojedine segmente koji nisu precizno uređeni ili nisu uređeni
- Akte o davanju u zakup poslovnih prostora potrebno je uskladiti sa zakonima
- Propisati obvezu izrade analize kod stjecanja nekretnina s ciljem utvrđivanja najpovoljnijeg načina stjecanja
- Potrebno je utvrditi jednaka pravila postupanja uz primjenu načela: jednakosti, predvidljivosti, učinkovitosti i odgovornosti, te pritom uvažavajući dugoročne strateške ciljeve

Nakon analize činjenica utvrđenih revizijom, DUR ocjenjuje upravljanje nekretninama kao učinkovito u samo 32 lokalne jedinice. Sve ostale jedinice lokalne samouprave djelomično učinkovito upravljaju imovinom. Upravljanje nekretninama ocijenjeno je učinkovito za devetnaest gradova i to abecednim redom su: Buzet, Čakovec, Duga Resa, Gospić, Karlovac, Kastav, Ivanec, Labin, Ludbreg, Opatija, Ozalj, Prelog, Senj,

Slavonski Brod, Slunj, Umag-Umago, Vinkovci, Virovitica i Zaprešić, te također za sedam županija i šest općina.

Provedba navedenih preporuka prema mišljenju DUR-a pridonijela otklanjanju utvrđenih slabosti kao i propusta u vezi s upravljanjem imovinom. Također, smatra se da bi to imalo pozitivan utjecaj na povećanje učinkovitosti upravljanja i raspolaganja nekretninama. DUR je izradio i pojedinačne izvještaje u kojima navodi konkretna mišljenja s preporukama mjera za poboljšanje.

4. PREGLED EMPIRIJSKIH ISTRAŽIVANJA O UČINKOVITOSTI UPRAVLJANJA NEKRETNINAMA

Ovo poglavlje analizira načine mjerenja učinkovitosti javne potrošnje. Pitanje učinkovitosti sve se više nameće kao važno ekonomsko pitanje, primarno zbog sve većeg rasta udjela rashoda u BDP-u. Upravo se ovim poglavljem želi pokazati kako postoji velika mogućnost za smanjenjem rashoda bez da se smanji postignuta razina outputa, te kako pitanje učinkovitog iskorištavanja ograničenih resursa mora biti stavljeno u prvi plan kod planiranja svakog projekta. Radi toga se u prvom dijelu ovog poglavlja definira opseg javnog sektora i njegove temeljne funkcije. Osim toga napravljen je i pregled različitih teorija ekonomike blagostanja. Time se želi pokazati kako je teorijski definirana uloga javnog sektora i unutar kojih bi se granica javna potrošnja trebala kretati.

U drugom dijelu ovog poglavlja proći će se kroz najvažnija istraživanja koja se bave pitanjem učinkovitosti javne potrošnje. Nakon toga će se proći kroz najvažnije metode kojima se može mjeriti ta učinkovitost. Analizirat će se koji su postupci mjerenja same učinkovitosti kod svake pojedine metode, što je posebno važno, s obzirom na to da su to „alati“ koji stoje na raspolaganju svima u javnom sektoru, a putem kojih se može mjeriti učinkovitost same potrošnje. Kao primjer upotrebe navedenih metoda iznijet će se zaključci radova Slijepčević (2009) i Bogović (2014) gdje će se vidjeti kako primjena različitih metoda može pomoći pri donošenju odluka o tome gdje i kako trošiti ograničene resurse. Na kraju će se detaljnije analizirati mogućnosti i problemi kod svake metode, te će se predložiti još neke alternativne metode koje možda mogu nadomjestiti probleme koji postoje kod ostalih metoda.

4.1. Važnost mjerenja učinkovitosti u javnom sektoru

Kako bi država što bolje osigurala ponudu javnih dobara i usluga, ona mora što učinkovitije koristiti ograničene resurse s kojima raspolaže. U idealnom slučaju oslanjanje na tržišni mehanizam bilo bi dovoljno za osiguravanje učinkovite raspodjele resursa u ekonomiji, no kao što je poznato postojanje tržišnih neuspjeha sprječava bilo koju državu da se u potpunosti osloni na taj mehanizam. U tu svrhu, mjerenje učinkovitosti postaje izrazito važan aspekt kod proučavanja javne potrošnje. Jer ponuda javnih dobara i usluga, poput ostalih tržišnih manjkavosti, zahtijeva uključivanje države. Radi te činjenice potrebno je provoditi analizu

učinkovitosti javne potrošnje kako bi se mogle predložiti promjene koje mogu poboljšati javnu potrošnju i tako omogućiti, što je više moguće, većem broju ljudi dostupnost javnih dobara i usluga. (Slijepčević, 2009) Naravno, osim ponude javnih dobara, država ima i druge funkcije. No prije toga treba reći što spada pod državu, odnosno javni sektor. Prema metodologiji Međunarodnog monetarnog fonda (2001) javni sektor se sastoji od različitih razina državne vlasti zajedno s javnim društvima koja su pod njenom kontrolom.

Slika 4.1 Javni sektor

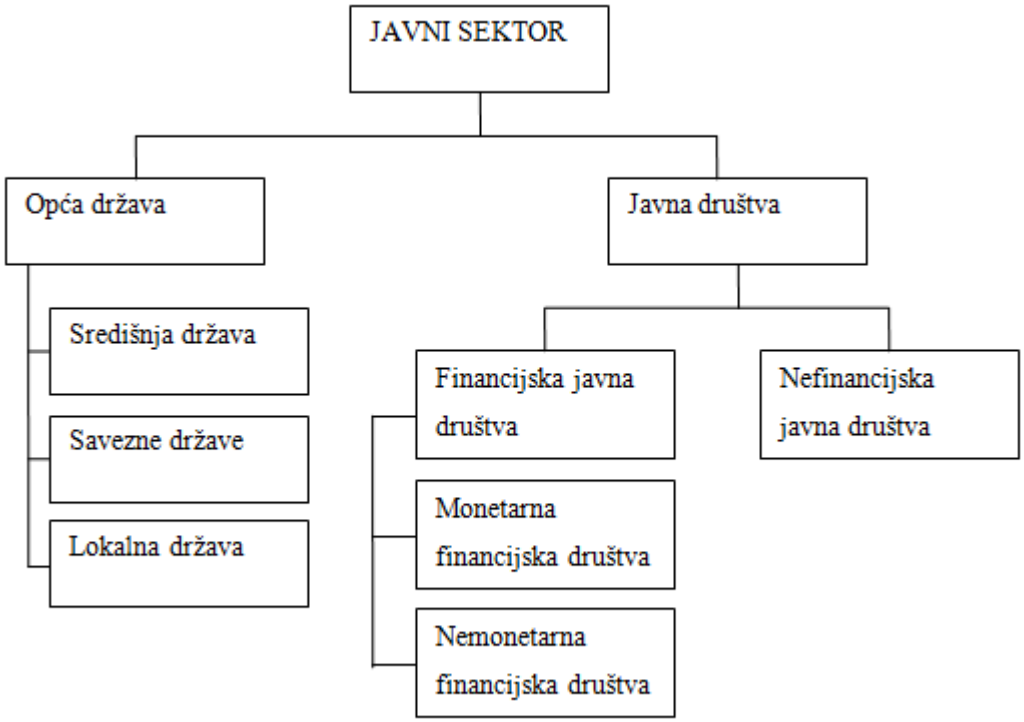

Izvor: Međunarodni monetarni fond (2001).

Prema MMF-u javni sektor se sastoji od svih razina vlasti koje imaju mogućnosti prikupljati svoje prihode i temeljim njih ostvarivati rashode. U Hrvatskoj se pod pojmom javnog sektora podrazumijeva opća država pod koju spada državni proračun kao i proračun jedinica lokalne i regionalne samouprave. Osim toga pod javni sektor uključujemo i javne financijske institucije koje kontrolira država, poput središnje banke ili nekih državnih poslovnih banaka, te nefinancijska javna poduzeća. Tu se misli na ona poduzeća koja su u većinskom vlasništvu države.

Pri mjerenju učinkovitosti primarno će se proučavati opća država zbog toga što se taj dio javnog sektora oslanja na korištenje fiskalne politike u provođenju svojih ciljeva, dok javne financijske

institucije primarno imaju monetarne učinke na gospodarstvo zbog čega one nisu obuhvaćene ovom analizom. Što se tiče poduzeća koja su pod većinskom upravom države, ona će biti obuhvaćena preko analize temeljnih funkcija javne potrošnje, a tu se misli na alokacijsku, redistributivnu i anticikličnu politiku. (Slijepčević, 2009) Nakon što je definirano što se smatra pod javni sektor, treba detaljnije navesti koje su njegove temeljne funkcije, no osim toga treba vidjeti kako se mogu vrednovati alternativne ekonomske politike i na koji način se one odabiru. Za taj drugi dio u ekonomskoj teoriji obično se poseže za ekonomikom blagostanja, o čemu će više biti riječi kasnije u tekstu.

No prije definiranja funkcija javnog sektora, treba naglasiti kako se učinkovitost jednako tako može mjeriti i na razini gradova. Sve veći broj ljudi živi u gradovima, posebno u Europi, što vodi sve većoj koncentraciji gospodarske aktivnosti. Zato lokalni ekonomski razvoj dobiva na sve većem značaju, jer na lokalnoj razini, kao i na državnoj, upravljanje ograničenim resursima i njihovo učinkovito korištenje ima važne učinke na buduću gospodarsku aktivnost. Specifičnost gradova u Republici Hrvatskoj je u tome što upravljanje gradom najviše ovisi o gradonačelniku, dakle o pojedincu. Stoga njegove osobine presudno određuju hoće li se nekim gradom učinkovito upravljati. Zbog toga se poseže za menadžerskim znanjima i praksama koje se koriste u privatnom sektoru kako bi gradonačelnici mogli što učinkovitije upravljati gradskim proračunom. Osim toga specifičnost gradova je potreba za bliskom suradnjom sa svojim građanima, radi čega osobne karakteristike gradonačelnika samo još više dobivaju na značaju. Iz navedenih razloga analiza učinkovitosti na gradskoj razini može pomoći gradonačelnicima kako bi od svojih gradova mogli napraviti ekonomski održive sredine. (Bogović, 2014)

Što se tiče funkcija javnog sektora, prema P. i R. Musgrave (1993) postoje tri funkcije koje se mogu smatrati temeljnima. Kao prvu možemo istaknuti alokacijsku funkciju. Njena uloga je učinkovito usmjeravati ograničena sredstva s kojima neka država raspolaže kako bi se zadovoljile potrebe stanovništva za javnim dobrima i uslugama. Upravo karakteristike javnog dobra omogućuju državnu intervenciju jer za razliku od privatnog dobra, javna dobra su nekonkurentna. Ona su svima dostupna pod istim uvjetima. To znači da korisnost i količina javnog dobra ne opada s povećanjem broja korisnika, odnosno trošak dodatnog korisnika je nula. Svi dakle mogu imati jednaku korist od tog dobra. Druga karakteristika je nemogućnost

isključivanja bilo koga iz njegove potrošnje. Radi toga ljudi nisu voljni platiti za takvo dobro jer kako ne mogu nikoga isključiti iz potrošnje tog dobra, nitko ne želi biti onaj koji će podnijeti trošak nabave tog dobra. Ta se situacija naziva problemom slobodnog jahača. To je pojam koji označava praksu neotkrivanja preferencija za određenim javnim dobrom od strane pojedinaca zbog čega se ne može utvrditi kolika bi bila optimalna količina određenog dobra koja bi zadovoljila sve korisnike. To naravno državi stvara problem jer ne može saznati kolike bi rashode trebala osigurati kako bi nabavila određeno dobro. Zbog toga se odluka o količini javnog dobra ostavlja „političkom tržištu" na kojem ljudi svojim glasovima i odabirom određene političke opcije biraju i ponudu javnog dobra koju određena stranka nudi. (Slijepčević, 2009; P. i R. Musgrave, 1993)

Osim neotkrivanja preferencija, pojedinci nekad nisu ni svjesni koliko im neko dobro pruža zadovoljstva, te stoga nisu u stanju procijeniti kolika bi bila optimalna količina takvog dobra. Tu je naravno problem što ljudi ne mogu posjedovati sve informacije, pa radi toga ne mogu ni „glasati" o tome koliku razinu takvog dobra žele. Tu se radi o specifičnoj vrsti dobra koje se naziva „meritornim dobrima". Radi toga država to dobro nabavlja samoinicijativno jer ne može računati da će pojedinci sami nabaviti takvo dobro. Pod meritorna dobra obično se navodi financiranje umjetnosti od strane države. Osim meritornih postoje i demeritorna dobra. To su obično dobra koja su štetna za pojedinca, no kao i kod meritornih, ljudi nisu u potpunosti svjesni njihovih posljedica, radi čega opet država opet mora uskočiti i smanjiti razinu potrošnje takvog dobra. Tu se obično pušenje navodi kao primjer demeritornog dobra. Jednako tako se paralela može povući i s pojmom „javna zla" koji označava potrošnju određenog dobra koje šteti svima i gdje nitko ne može biti isključen, poput ispušnih plinova ili zagađene vode. Tu također država treba intervenirati ulaganjem u tehnologije koje mogu smanjiti razinu zagađenja i tako svima omogućiti čist zrak i vodu. (Slijepčević, 2009; Brümmerhoff, 1997)

Javna dobra nisu jednoznačna, kod njih također postoji podjela prema mogućnosti isključivanja iz potrošnje i prema razini konkurencije pri korištenju određenog dobra. Dakle, postoji određena gradacija od privatnih prema javnim dobrima. Upravo nam tablica 1. može poslužiti kao dobar prikaz razgraničenja između javnih i privatnih dobara.

Tablica 4-1 Obilježja javnih i privatnih dobara

		Isključivanje iz potrošnje	
		Moguće	Nemoguće
Potrošnja	Konkurentska	Čista privatna dobra (individualna dobra)	Mješovita dobra
	Nekonkurentska	Mješovita dobra (nepotpuno javna ili privatna dobra)	Čista javna dobra (kolektivna dobra)

Izvor: Jurković (2002).

Vidimo kako osim čistog javnog dobra, koja su veoma rijetka, pri čemu se tu obično navodi nacionalna obrana kao primjer, i privatnog dobra, postoji i specijalni oblik koji se zove mješovito dobro. Naime, javno dobro ipak može postati konkurentno i može smanjiti razinu koristi koju pojedinac može ostvariti. To obično ovisi o količini potrošača. Ako određeno dobro koristi previše ljudi, onda tu nastaje problem gdje određeni pojedinci postaju isključeni iz njegovog korištenja i na taj način dobro sve više počinje dobivati karakteristike privatnog dobra, a ne više javnog dobra. (Slijepčević, 2009; Brümmerhoff, 1997)

Osim alokacijske, država isto tako može vršiti funkciju preraspodjele dohotka. Naime, tržište uzrokuje velike razlike u dohotku koje ostvaruju pojedinci, no ne samo pojedinci, nego i čitave regije. Stoga država mora uskočiti kako bi sve te razlike svela na društveno prihvatljivu razinu. Ovdje opet vidimo kako se putem političkih odluka moraju napraviti određene intervencije koje nije moguće ostvariti isključivo putem tržišnog mehanizma. Tržište je primarno orijentirano na postizanje učinkovite preraspodjele i ono ne mari za pravednost u ishodima. Državnim miješanjem mogu se uzrokovati određene neučinkovitosti, stoga se intervencija mora svesti na prihvatljivu razinu kako se ne bi u potpunosti poremetila učinkovitost. Dakle, vidimo kako tu postoji određeni kompromis između učinkovitosti i pravednosti. Na to pitanje ekonomska znanost ne daje odgovor, to svako društvo mora samostalno odlučiti za sebe. Pri tome se mora imati na umu kako svako povećanje pravednije raspodjele može dovesti do većeg žrtvovanja učinkovitosti. Prema P. i R Musgrave (1993) postoje različiti načini na koji se može vršiti preraspodjela putem porezne politike. Moguće je oporezivati pojedince koji imaju visoke dohotke, kao i nametati više razine poreza na dobra i usluge koje većinom koriste takvi

pojedinci, dok je s druge strane moguće subvencionirati dohodak i potrošnju onih pojedinaca koji putem tržišta ostvaruju niske razine dohotka, no osim subvencioniranja moguće je i financirati javna dobra i usluge od kojih svi pojedinci mogu imati korist. (Slijepčević, 2009)

Posljednja funkcija javnog sektora je stabilizacijska. Ona je primarno orijentirana na makroekonomsku razinu gdje država putem intervencije pokušava ostvariti ciljeve poput stabilnosti tečaja, niske inflacije ili stabilnog gospodarskog rasta, kao i mnoge druge ciljeve. Na taj način država može osigurati da njeno gospodarstvo ostvaruje punu iskorištenost svojih proizvodnih kapaciteta, odnosno da ne postoje neiskorišteni resursi. Tu se analiza učinkovitosti obično može vršiti putem usporedbe, gdje ona država koja ima najveću učinkovitost u proizvodnji može poslužiti drugima kao primjer prema kojemu će se ostale moći orijentirati, odnosno radi se o relativnoj učinkovitosti. (Slijepčević, 2009)

Nakon pregleda temeljnih funkcija, treba vidjeti kako država može odabrati koje odluke donijeti. Kao što je već navedeno, za to može poslužiti ekonomika blagostanja. Ona pomaže pri ocjeni je li određena alokacija učinkovita ili nije, te tko je dobitnik, a tko gubitnik i u kojoj mjeri je moguće popraviti blagostanje pojedinca koji se nalazi u lošijoj poziciji, bez da se pogorša stanje ostalih i tako sve dok se ne ostvari situacija gdje više nije moguće povećati ničije blagostanje. (Slijepčević, 2009; Brümmerhoff, 1997)

Naravno, postavlja se pitanje kako mjeriti društveno blagostanje. U literaturi postoji više prijedloga, zbog čega će se proći kroz nekoliko mogućih načina na koji ga vlasti mogu mjeriti. Jedan od prvi prijedloga kako mjeriti društveno blagostanje je putem ekonomskog rasta. Naime, ekonomski rast označava povećanje dostupne količine dobara i usluga, pri čemu važnu ulogu ima učinkovitost bez koje je nemoguće imati dugoročno održive stope gospodarskog rasta. No tu se javlja problem jer osim postizanja učinkovitosti koja omogućuje gospodarski rast, pitanje pravednosti također igra važnu ulogu kod mjerenja društvenog blagostanja, stoga ovaj način nije u potpunosti adekvatan. Postoji i kardinalističko mjerilo gdje se smatra kako je za postizanje maksimalne razine društvenog blagostanja potrebno ostvariti jednaku raspodjelu dohotka između svih pojedinaca. Naravno, tu se pretpostavlja kako svi imaju jednaku funkciju koristi novca, no to nije slučaj u stvarnosti jer neki pojedinci vrednuju razinu bogatstva više

nego drugi, stoga bi upotreba ovakvog pristupa dovela do smanjenja društvenog blagostanja. (Koutsoyiannis, 1996)

Jedna od najčešće korištenih mjera društvenog blagostanja je pristup Pareto-optimalnosti. Prema tom pristupu situacija koja se naziva Pareto-optimalna, odnosno Pareto-efikasna, je ona gdje se ni jednom pojedincu ne može povećati blagostanje bez da se ono ne smanji nekom drugom pojedincu. Tu dakle vlasti moraju paziti da odaberu onaj projekt koji je u stanju povećati društveno blagostanje na način da se stanje barem jednog pojedinca poveća bez da se nekog drugog smanji. To bi bio princip Pareto-poboljšanja. Naravno, to je veoma teško postići u stvarnosti jer rijetko kad ne postoji ni jedan gubitnik kod bilo koje politike. Zato i postoji određena nadogradnja ovog kriterija, no pozitivna strana principa Pareto-optimalnosti je činjenica da se različite funkcije korisnosti ne uspoređuju, pri čemu se dopušta različita razina korisnosti za svaku pojedinca. To principu Pareto-optimalnosti daje objektivnost, koja nedostaje kod dva prethodna principa. (Slijepčević, 2009; Ahlheim, 2002; Koutsoyiannis, 1996)

Za jasniji prikaz principa Pareto-optimalnosti možemo se poslužiti slikom 4.2 gdje je prikazana opća ravnoteža alokacije.

Slika 4.2 Opća ravnoteža alokacije

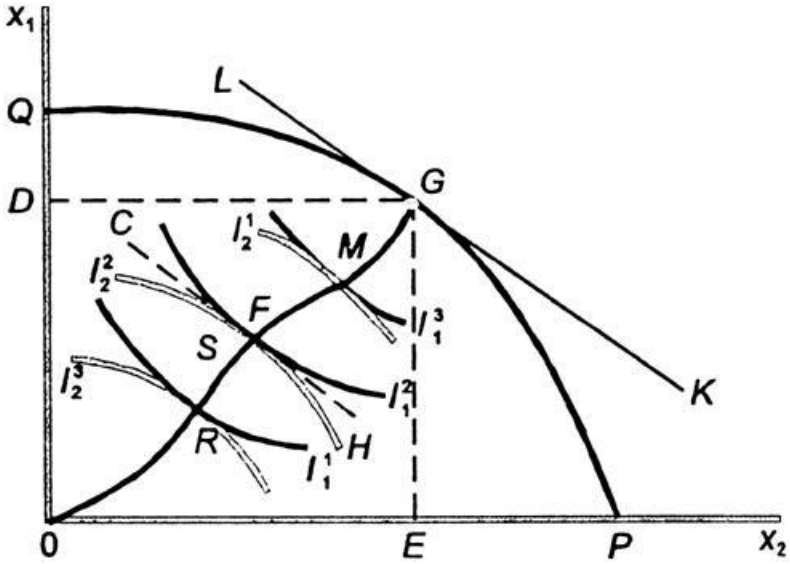

Izvor: Brümmerhoff (1997).

Na slici imamo konveksne krivulje indiferencije I_1^n i krivulje transformacije označene kao I_2^n. Poznato je kako se udaljavanjem krivulje indiferencije od ishodišta povećava razina korisnosti

pojedinca. Osim toga na slici imamo i krivulju transformacije OP; ona označava krivulju proizvodnih mogućnosti odnosno najveću moguću razinu proizvodnje dobara x_1 i x_2 koje je moguće postići uz danu razinu tehnologije. Na grafu još imamo i dva pravca. Prvi pravac CH koji tangira krivulju indiferencije i predstavlja graničnu stopu supstitucije odnosno njen nagib, dok drugi pravac LK koji tangira krivulju OP predstavlja graničnu stopu transformacije, tj. nagib krivulje OP. Ako bi razina proizvodnje bila maksimalna, što je na grafu prikazano točkom G, onda su kombinacije mogućih razina potrošnje dane krivuljom 0G gdje su točke R, F, M i G moguće razine ravnoteže u kojima se može ostvariti optimalna razina proizvodnje i razmjene. No kao što vidimo, to je jedino moguće ostvariti u točki F gdje je nagib krivulje indiferencije jednak nagibu krivulje tržišne transformacije, pa se stoga ta točka smatra Pareto-optimalnom. Na taj je način zadovoljena najveća razina korisnosti pojedinca kao i cjelokupnog gospodarstva pri čemu se smatra da su zadovoljeni kriteriji maksimizacije dobiti i korisnosti, a savršena informiranost jedan je od važnih preduvjeta cijele te priče. Treba napomenuti kako je moguće postići Pareto-optimalno stanje bez da se ostvari maksimalno društveno blagostanje; to dakle naglašava da pred nositeljima politike, kao i građanima, postoji izbor koja razina blagostanja im je prihvatljiva, te ako žele mogu i promijeniti danu razinu blagostanja. (Slijepčević, 2009)

Sljedeći kriterij je Kaldor-Hicksova učinkovitost. Ona odbacuje Paretov princip gdje nitko ne može biti oštećen određenim projektom. Stoga ovaj princip uspoređuje troškove i koristi od određenog projekta i onaj projekt koji ima veće koristi od nastalih gubitaka smatra se prihvatljivim. Jer ako je sadašnja vrijednost koristi od nekog projekta veća od troškova, onda oni koji su gubitnici mogu se nadoknaditi, dakle tu se gleda je li moguće barem postići Pareto-poboljšanje. Ovaj princip je iz toga razloga češće u upotrebi, no mana ovog pristupa je što ne uzima u obzir kako je određeni projekt utjecao na raspodjelu dohotka, jer sve dok je projektom postignuta veća razina koristi od gubitaka, projekt je prihvatljiv, bez obzira što se može dogoditi situacija gdje su se gubici većinom ostvarili kod siromašnog pojedinca. Ovaj se princip smatra određenom nadopunom Pareto-optimalnog principa gdje se želi vidjeti vodi li određena promjena prema Pareto-efikasnom rješenju. (Slijepčević 2009; Rosen, 1999)

Bergsonovo mjerilo polazi do toga da se treba vrednovati neki projekt jedino ako postoji vrijednosni sud o tome koliko je koji pojedinac ili skupina zaslužna. Pa onda funkcija društvenog blagostanja, koja je u osnovi funkcija individualnih koristi, sadrži skup vrijednosnih

sudova o zaslužnosti svakog pojedinca. Prikazuje se Bergsonovim obrisima blagostanja kao što je prikazano na slici 4.3.

Slika 4.3 Bergsonovi obrisi blagostanja

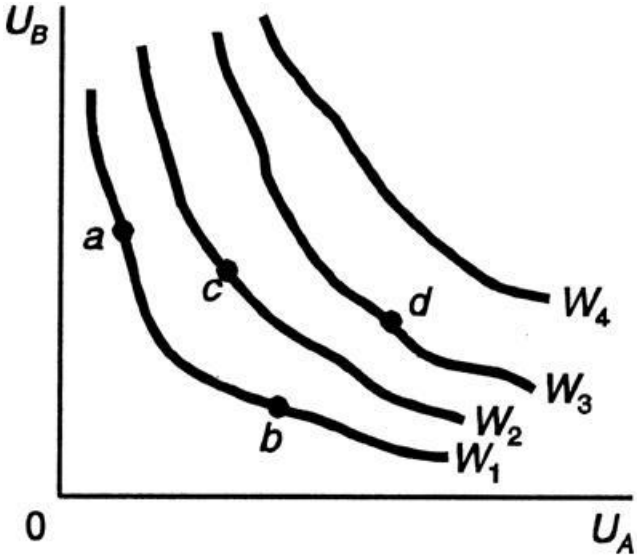

Izvor: Koutsoyiannis (1996)

Kao posljednje mjerilo ističe se Benthamovo utilitarističko mjerilo blagostanja. On ne polazi od pojedinca, nego od čitavog društva gdje smatra da se povećanje blagostanja ostvaruje kad se poveća korist većini pojedinaca. Naravno, nedostatak je što se ne uzima u obzir zaslužnost svakog pojedinca što ga čini različitim od prethodnog Bergsonovog mjerila. (Slijepčević, 2009)

4.2. Pregled dosadašnjih istraživanja i metoda za ocjenu učinkovitosti

U ovom dijelu rada bit će napravljen pregled istraživanja koja su se bavila pitanjem učinkovitosti javnog sektora, s tim da treba napomenuti kako se radi o istraživanjima koja u svojoj analizi primarno koriste jednu od parametarskih ili neparametarskih metoda. Nakon toga će se detaljno opisati razvoj svake pojedine metode gdje će vidjeti svrha i upotreba različitih metoda.

Može se reći kako se veća potreba za analizom učinkovitosti u javnoj potrošnji javlja tijekom 70-ih godina prošlog stoljeća. Tada se počelo s primjenom metoda koje su se dotad koristile

isključivo u privatnom sektoru. Što se tiče istraživanja koja se bave analizom učinkovitosti u Hrvatskoj, ona su relativno oskudna, dok u svijetu postoji veliki broj istraživanja na temu učinkovitosti javnog sektora. Analiza učinkovitosti može se provoditi putem analize određene organizacije poput pojedinačne bolnice ili se može analizirati određeno područje javnog sektora poput cjelokupnog zdravstvenog ili obrazovnog sustava. Postoji isto tako i analiza koja se bavi razvojem metodologije koja bi omogućila ocjenu cjelokupnog javnog sektora kao i mogućnost usporedbe rezultata između različitih država. (Slijepčević, 2009)

Kod analize institucija postoji mogućnost za jasno mjerenje outputa dane institucije gdje se može vidjeti pruža li neka institucija dovoljnu razinu usluge s obzirom na količinu resursa s kojima raspolaže. Tu se obično analizira učinkovitost pojedine bolnice gdje se nakon toga njezini rezultati uspoređuju s rezultatima drugih sličnih bolnica. Isto se veoma često analiza provodi i kod učinkovitosti poslovanja određenih škola i fakulteta. Naravno, osim analize pojedinih institucija može se analizirati i cjelokupni sektor zdravstva i obrazovanja, a ne samo njihovi pojedini dijelovi. U istraživanju cjelokupnog sektora posebno se ističu države poput Velike Britanije, Finske, Švedske i Australije. Najčešće korištena metoda u tim istraživanjima je metoda omeđivanja podataka i metoda *Free Disposable Hull*. Upravo su u tablici 2. prikazana važnija istraživanja u sektoru obrazovanja gdje se vidi koliko koja država ima prostora za smanjenje svojih rashoda bez da smanji razinu outputa. (Slijepčević, 2009)

Također, veoma često istraživanja se provode i u sektoru javnog reda i sigurnosti. Od značajnih možemo navesti istraživanje Carrington, Puthucheary i Rose (1997) koje se bavi analizom učinkovitosti policije u južnom Walesu, a slična istraživanja učinkovitosti policije u Engleskoj i Walesu su istraživanja Drakea i Simpera (2001), (2002) i (2005) godine. Jednako tako je rađeno istraživanje policije u Španjolskoj od strane Diez-Ticina i Maccebona (2002). Osim analize učinkovitosti policije često se rade i analize učinkovitosti sudova. Tu se ističu istraživanja 21 suda u Španjolskoj od strane Pedraja-Chaparro i Salinas-Jimeneza (1996), kao i istraživanje Schneidera (2005) koji analizu vrši nad prizivnim sudovima u Njemačkoj. Sve ove analize provođene su putem neparametarske metode analize omeđivanja podataka, osim jednog istraživanja koje uz analizu omeđivanja podataka provodi istraživanje i putem parametarske metode stohastičke funkcije troška.

Tablica 4-2 Prikaz mogućnosti za povećanje učinkovitosti u sektoru obrazovanja

Država/Autori	Clements (2002)	Gonand, Joumard i Price (2007)	Afonso, Schuknecht i Tanzi (2006)	Afonso i St. Aubyn (2004)
Austrija	1,3	6,0	9,5	5,4
Belgija	-	2,0	5,5	6,5
Češka	0,9	6,0	6,8	7,6
Danska	1,7	4,9	9,3	8,4
Finska	0,0	1,6	0,0	0,2
Francuska	1,3	5,4	7,2	6,6
Njemačka	1,3	9,1	8,3	10,3
Grčka	0,0	7,0	8,2	5,7
Mađarska	0,5	4,7	10,5	0,0
Irska	0,0	2,2	7,9	5,0
Italija	1,4	6,9	5,1	12,8
Nizozemska	1,1	5,1	3,7	-
Poljska	-	3,8	-	0,0
Portugal	5,3	2,2	6,1	15,8
Slovačka	-	5,3	1,8	-
Španjolska	2,0	3,4	2,9	10,1
Švedska	1,7	6,0	0,0	5,3
Velika Britanija	-	6,1	-	2,4

Izvor: Slijepčević (2009).

Što se tiče mjerenja učinkovitosti u Hrvatskoj, ona su veoma rijetka. Kao značajnija se mogu navesti sljedeća tri rada. Prvo Jemrić i Vujčić (2002) analiziraju učinkovitost u bankarskom

sektoru gdje uspoređuju poslovanje između banaka u privatnom i državnom vlasništvu kao i između domaćih i stranih banaka. Metoda koju koriste je analiza omeđivanja podataka. Bahovec i Neralić (2001) vrše analizu nad poljoprivrednim sektorom gdje isto putem analize omeđivanja podataka gledaju učinkovitost poljoprivredne proizvodnje na razini općina u razdoblju od 1980. do 1990. godine. Kao posljednje istraživanje ističe se ono Jafarova i Gunnarssona (2008) gdje uspoređuju razinu učinkovitosti socijalne potrošnje između Hrvatske i 10 novih članica Europske unije. Tu su kao područje istraživanja uzeli sektor obrazovanja, zdravstva i socijalne potrošnje, te zaključili kako Hrvatska ima neučinkovitost u potrošnji u sektoru zdravstva i obrazovanja, dok se kod potrošnje za socijalnu zaštitu nalazi na granici učinkovitosti. Detaljniji prikaz uzetih varijabli na temelju kojih je mjerena učinkovitost prikazan je u tablici. (Slijepčević, 2009)

Analiza koja se bavi razvojem metodologije koja služi za ocjenu cjelokupnog javnog sektora ima za cilj razviti indikatore koji bi mogli omogućiti usporedbu između različitih zemalja, te uvidjeti kolike su koristi od porasta javne potrošnje u nekoj zemlji. Na osnovu te usporedbe zemlje mogu vidjeti kolika je uspješnost njihovih reformi, te mogu, uspoređujući se s učinkovitijim državama, poboljšati način na koji koriste resurse. Problem kod ovog tipa istraživanja je u nedostatku raspoloživih podataka. Radi toga su međunarodne organizacije poput Svjetske banke i OECD-a počele s izgradnjom baza podataka i razvijanjem međunarodno usporedivih indikatora koji bi omogućili lakše provođenje ovakvog tipa analize. Pošto postoje mnoga istraživanja koja se bave ovom tematikom, izdvojit će se dva značajnija istraživanja u ovom području koja su slična radu koji je provela i Slijepčević (2009).

Tablica 4-3 Prikaz varijabli za mjerenje učinkovitosti sustava socijalne potrošnje

Područje	Rashodi	Outputi	Ishodi
Obrazovanje	Rashodi za obrazovanje.	Omjer broja učenika i nastavnika. Stopa upisa Stopa prijelaza na srednjoškolsko obrazovanje. Stopa završetka školovanja.	Prosječan uspjeh na međunarodnom standardiziranom ispitivanju iz matematike.
Socijalna zaštita	Transferi za socijalnu zaštitu.	-	Stopa siromaštva mjerena Ginijevim koeficijentom.
Zdravstvo	Rashodi za zdravstvo.	Indeks gustoće liječnika, ljekarnika i zdravstvenih djelatnika. Broj bolničkih kreveta. Broj cijepljenja.	Stopa smrtnosti dojenčadi, djece i rodilja. Stopa smrtnosti od svih uzroka. Incidencija tuberkuloze. Prosječno očekivano trajanje života u dobrom zdravlju.

Izvor: sistematizacija Slijepčević (2009) na temelju Jafarov i Gunnarsson (2008).

Prvo istraživanje je Ureda za socijalno i kulturno planiranje iz Nizozemske koje je provelo istraživanje u 29 zemalja na temelju četiri sektora javnog sektora: obrazovanja, zdravstva, pravosuđa i jasne uprave. Za mjerenje troškovne učinkovitosti svakog sektora uzeti su određeni indikatori, tako su za obrazovanje uzeti indikatori poput pokazatelja očekivane kvalitete obrazovanja ili pokazatelji matematičkog znanja i ostali slični pokazatelji. Jednak postupak je napravljen i za ostale sektore. Onda su za svaki sektor na temelju tih pojedinačnih pokazatelja izvedeni kompozitni pokazatelji ili indeksi poput indeksa zdravstvenog stanja koji su stavljeni u odnos s rashodima po pojedinom sektoru. I onda na kraju se svi ti pokazatelji kombiniraju u

jedan skupni indeks rezultata ukupne aktivnosti javnog sektora pomoću kojeg se onda mogu vršiti usporedbe između različitih zemalja. (Slijepčević, 2009)

Sljedeće istraživanje su proveli Afonso, Schuknecht i Tanzi (2003). Oni su kompozitni indeks kojim mjere aktivnost cjelokupnog javnog sektora napravili tako da su prvo promatrali učinkovitost državne uprave, a potom učinkovitost države u izvršavanju svojih temeljnih aktivnosti. Nakon toga su taj indeks stavili u odnos s udjelom javnih rashoda u BDP-u, pri čemu je mjerenje učinkovitosti provedeno putem metode *Free Disposable Hull*. Pregled ovog i ostalih istraživanja koja su napravili isti autori može se vidjeti u tablici gdje se može vidjeti različita metodologija koja je korištena u različitim radovima.

Tablica 4-4 Pregled istraživanja

Autor	Države	Metoda mjerenja učinkovitosti	Varijable
Afonso, Schuknecht i Tanzi (2003)	23 države OECD-a	*Free Disposable Hull* (FDH)	Output: indikatori koji odražavaju rezultate javnog sektora – odabrani socioekonomski indikatori za kvalitetu javne uprave, obrazovanje, zdravstvo, javnu infrastrukturu, raspodjelu dohotka, ekonomsku stabilnost i ekonomske rezultate. Input: udio javne potrošnje u bruto domaćem proizvodu.
Afonso, Schuknecht i Tanzi (2006)	10 država EU koje su postale članice 1. svibnja 2004. g. Odabrane druge ekonomije u nastajanju	Analiza omeđivanja podataka (DEA) Tobit analiza	Output: rezultati za javnu upravu, obrazovanje, zdravstvo, raspodjelu dohotka, stabilnost i ekonomske rezultate. Input: udio javne potrošnje u bruto domaćem proizvodu.

Afonso, Schuknecht i Tanzi (2008)	Australija, Austrija, Belgija, Češka, Danska, Finska, Francuska, Njemačka, Grčka, Mađarska, Irska, Italija, Japan, Kanada, Luksemburg, Nizozemska, Novi Zeland, Norveška, Poljska, Portugal, Slovačka, Švicarska, USA, Velika Britanija	Analiza omeđivanja podataka (DEA) Tobit analiza	Promatra se utjecaj javne potrošnje na raspodjelu dohotka u razvijenim ekonomijama.

Izvor: sistematizacija Slijepčević (2009).

Od ostalih istraživanja koja su analizu učinkovitosti u Hrvatskoj vršila putem metode omeđivanja podataka možemo navesti ona koja su se bavila gospodarskim sektorom poput Hunjet (1998), Šporčić i ostali (2008. i 2010.). Uslužnim sektorom bavila su se istraživanja: Neralić (1996), Petrov (2002), Hunjak i Jakovčević (2003), Šegota (2003 i 2008). Javnim sektorom bavio se Jafarov (2008) koji se istraživao učinkovitost socijalnog sustava u RH i usporedio ga je sa zemljama EU-a, te Rabar (2010) koja analizira učinkovitost hrvatskog bolničkog sustava, gdje se došlo do rezultata koji ukazuje kako je 78% hrvatskih bolnica neučinkovito i radi toga se u radu preporučuje usporedba s učinkovitijim bolnicama kako bi se popravile neučinkovitosti. (Bogović, 2014)

Jednako tako se u sklopu analize koja se bavi razvojem metodologije može analizirati i učinkovitost pojedinih lokalnih jedinica. Tu je posebno zanimljiv jedan rad koji je najbliži tematici koju obrađuje Bogović (2014), a radi se o radu Škuflić, Rabar i Šokčević (2010) gdje se putem metode omeđivanja podataka pokušava procijeniti relativna učinkovitost hrvatskih županija na način da su mjerili razinu gospodarskog rasta u odnosu na granicu proizvodnih mogućnosti. U radu se analizira 5 inputa i 2 outputa, s 21 analiziranom jedinicom čime se zadovoljava uvjet kako broj jedinica mora biti 2 do 3 puta veći nego broj inputa i outputa.

(Hunjak i Jakovčević, 2003.; Rabar, 2010.) Analizom se došlo do rezultata koji pokazuju kako županije mogu ostvarivati jednaku razinu učinkovitosti i s manjom razinom iskorištenosti dostupnih resursa. No problem kod ovog istraživanja je taj što zbog odabira inputa i outputa koji nisu pod izravnom kontrolom razine vlasti nad kojom se vrši analiza, rezultati ove analize mogu biti od veoma male pomoći regionalnim vlastima kako bi popravile to stanje, jer oni nemaju presudan utjecaj nad odabranim indikatorima. (Slijepčević, 2009; Bogović, 2014)

4.2.1. Razvoj metodologije za mjerenje učinkovitosti

Nakon pregleda relevantnih istraživanja, u ovom dijelu rada prikazat će se različite metode koje su dostupne vlastima kako bi im pomogle da u korištenju svojih resursa budu što učinkovitiji. Sam pojam učinkovitosti označava alokativnu i tehničku učinkovitost. Alokativna učinkovitost obično se izjednačava s Paretovom optimalnošću, gdje je postignuta takva razina proizvodnje gdje nije moguće poboljšati stanje ni jednog pojedinca bez da se ne pogorša stanje nekog drugog pojedinca. No ipak treba reći kako se radi o veoma strogom kriteriju, pa se stoga često uzima Kaldor-Hicksova učinkovitost kao kriterij učinkovitosti. (Brümmerhoff, 1997) Tehnička učinkovitost proučava koliko je resursa utrošila pojedina institucija u proizvodnji danog outputa, gdje se smatra kako je ona ostvarena kad je output postignut uz najniže moguće troškove. Kao dio tehničke učinkovitosti javlja se troškovna učinkovitost koja se temelji na usporedbi troškova jedne institucije s onom koja između svih drugih institucija ima najučinkovitiji način postizanja outputa, pa se gleda koliko određena institucija odskače od najbolje. Samo poboljšanje učinkovitosti moguće je postići ili kroz smanjenje inputa uz istu razinu outputa ili na strani outputa kroz njegovo povećanje uz jednaku razinu inputa. Jedna specifičnost javnog sektora posebno se mora uzeti u obzir. A to je činjenica da nekada država mora pružiti određene usluge bez obzira hoće li od toga imati profit ili ne. Tako da je kod mjerenja učinkovitosti u javnom sektoru važno uzeti u obzir i socijalne potrebe. Radi toga se za mjerenje učinkovitosti uzimaju određeni pokazatelji učinkovitosti javnog sektora i to relativno u odnosu na druge uspješnije zemlje, a ne čisti profit. Za pregled osnovnih metoda kojima se mjeri učinkovitost može poslužiti tablica gdje je napravljena podjela između osnovnih analitičkih metoda, te kvantitativnih metoda koje se dijele na parametarske i neparametarske. Više detalja o pojedinim metodama bit će u sljedećem dijelu rada. (Slijepčević, 2006; Brűmmerhoff, 1997)

Tablica 4-5 Pregled osnovnih metoda za mjerenje učinkovitosti

Osnovne analitičke metode (metode ekonomske analize)	Kvantitativne metode	
	Statističke (parametarske) tehnike/metode	Matematičke (neparametarske) metode
Analiza troškova i koristi	Analiza stohastičke funkcije (engl. *stohastic frontier analysis*)	Analiza omeđivanja podataka
Analiza troškova i učinkovitosti	Regresijske tehnike i metode	*Free Disposable Hull*
Analiza troškova i korisnosti	Statističke metode	Druge metode linearnog i nelinearnog programiranja (npr. Simpleks metoda[46])
Analiza minimizacije troškova		Pokazatelji uspješnosti, odnosno pokazatelji koji odražavaju rezultate aktivnosti po područjima javnog sektora

Izvor: Slijepčević (2006) na temelju Jurković (2002).

Naravno, isto tako treba napomenuti kako usporedba postignute učinkovitosti između različitih zemalja može biti jako problematična. Razloga je puno. Kao problem navodi se činjenica kako svaka zemlja zasebno definira što smatra pod javne usluge. Nadalje, svaka zemlja ima različite ciljeve koje želi postići u pojedinom području zbog čega se ne mogu lako usporediti rezultati obrazovanja u dvije različite zemlje. Postoje i metodološki problemi gdje različite zemlje imaju različit obuhvat podataka nad kojima se vrši analiza učinkovitosti, radi toga se i pokrenula uspostava međunarodnih baza podataka koje bi omogućile lakšu usporedivost podataka i bolje mjerenje učinkovitosti javnog sektora. No unatoč svim tim problemima smatra se kako u svim zemljama EU-a postoji veliki prostor za smanjenje javnih rashoda bez da se žrtvuje dostignuta razina outputa. (Slijepčević, 2009; European Commission, 2004)

- ***Analiza troškova i koristi (eng. Cost benefi)t***

Jedna od prvih i najčešće korištenih osnovnih analitičkih metoda je svakako *cost benefit* analiza. Temelj za *cost benefit* analizu je teorija blagostanja iznesena ranije u radu. U razmatranju između više mogućih investicija država mora procijeniti funkciju društvenog blagostanja kojom se po završetku projekta mjeri društveno blagostanje, te ako se ono poveća, onda se smatra kako je projekt dobar i kako ga treba ostvariti. Ipak, treba napomenuti kako ta metoda ne može biti od koristi kad su u pitanju odluke na dnevnoj bazi, no ona ipak predstavlja početnu osnovu za analizu troškova i koristi određenog projekta.

U praksi je čak unesena u američko zakonodavstvo gdje je propisano kako se neki projekt može smatrati prihvatljivim jedino ako su koristi od tog projekta veće od njegovih troškova. Na taj način analiza troškova i koristi omogućuje političarima ono što tržište samo radi, a to je preraspodjela resursa u one projekte gdje je granična društvena korist veća od graničnih društvenih troškova. Sama analiza sadrži nekoliko koraka. Potrebno je jasno definirati projekt u koji se želi ulagati, zatim se utvrđuju očekivani troškovi i koristi, nakon čega se izabire diskontna stopa, s tim da treba naglasiti kako različite vrijednosti diskontne stope mogu dovesti do različitih odluka o tome koji je projekt prihvatljiv. Diskontna stopa treba što je više moguće odražavati oportunitetne troškove korištenja resursa koje posjeduje određena ustanova. Ako je diskontna stopa previsoka, ona će projekte kod kojih se povrat od projekta ostvaruje kasnije u budućnosti, staviti u nepovoljniji položaj. Nakon utvrđivanja diskontne stope ide računanje sadašnje neto vrijednosti svih očekivanih troškova i koristi od nekog projekta. (Jurković, 2002; P. i R. Musgrave, 1993) To se računa pomoću sljedećih formula.

$$PV_R = \sum_{i=1}^{n} \frac{B_i}{(1+r)^i} - \sum_{i=1}^{n} \frac{C_i}{(1+r)^i} \text{ ili } PV_K = \frac{\sum_{i=1}^{n} \frac{B_i}{(1+r)^i}}{\sum_{i=1}^{n} \frac{C_i}{(1+r)^i}}$$

Sadašnja vrijednost koja je označena s PV smatra se prihvatljivom ako je $PV_R > 0$, tj. $PV_K > 1$. Dakle, prihvatljiv je samo onaj projekt koji ima pozitivnu sadašnju vrijednost, a u slučaju da su dva projekta međusobno konkurentna, onda se izabire onaj koji ima veću sadašnju vrijednost. Treba upozoriti da se kod korištenja omjera koristi i troškova bilo koji projekt može napraviti prihvatljivim, stoga treba biti jako oprezan pri njegovom izračunu. (Slijepčević 2009; Rosen, 1999)

- ***Analiza troškovne učinkovitosti (eng. Cost effectiveness)***

Druga značajna osnovna analitička metoda je analiza troškova i učinkovitosti. Ona se koristi kad nije moguće izračunati koristi nekog projekta. Ova je metoda isto tako jako dugo u uporabi. Počela se koristiti u SAD-u još 50-ih godina prošlog stoljeća. Ona služi za usporedbu između različitih projekta gdje se izabire onaj projekt koji je troškovno najučinkovitiji. Takav se projekt, iz razloga jer se ne može znati kolike su njegove koristi, smatra najboljim. (Slijepčević, 2009)

Prema Jurkoviću (2002) moguća su tri načina na koja se može odabrati projekt korištenjem ove metode. Prvi način je izbor onog projekta koji ostvaruje zadani cilj ili nekoliko njih uz najmanje troškove. Drugi način je da se odabere onaj projekt koji najbliže ostvaruje ono što se htjelo postići danim ciljem jer bolje rezultate nije moguće ostvariti zbog ograničenih resursa. Te kao zadnja opcija, da se odabere onaj projekt koji daje najbolji omjer između željenog cilja i razine troškova koji su utrošeni kako bi se cilj ostvario.

Sama analiza provodi se kroz nekoliko koraka. Prvobitno se definira cilj ili više njih koji se žele ostvariti, nakon čega se gledaju svi mogući alternativni načini ostvarenja zadanog cilja. Potom se određuje razina resursa koja će biti potrebna za ostvarivanje željenog cilja, te se na kraju mjeri najučinkovitiji način ostvarivanja željenog projekta. Treba napomenuti kako je važno da postoji više mogućih alternativnih načina za ostvarivanje određenog projekta jer cilj ove analize nije smanjiti troškove, već odabrati onaj projekt koji će biti najučinkovitiji s obzirom na danu razinu dostupnih resursa. (Jurković, 2002; Sever, 1995)

Postoje još dvije dodatne analitičke metode koje se neće detaljnije objašnjavati, a radi se o analizi troškova i korisnosti, te analizi minimizacije troškova. Analiza troškova i korisnosti smatra se podvrstom analize troškova i učinkovitosti te se najčešće koristi u zdravstvu. Kod nje se koristi ne izražavaju u novčanom iznosu, nego samo troškovi. Analiza minimizacije troškova pruža mogućnost odabira onog projekta koji ima najniže troškove. (Slijepčević, 2009)

4.2.2. Parametarske metode

Kvantitativne metode pod koje spadaju i parametarske metode razvile su se na temelju Farrelovih pretpostavki o čemu će više riječi biti kasnije u radu. Opis parametarskih metoda možemo započeti s regresijskom analizom. To je statistička metoda koju je Slijepčević (2009) u svojem radu iskoristila kako bi analizirala neke vanjske čimbenike koji utječu na učinkovitost javne potrošnje. Tu se pod vanjske učinke misli na sve one učinke koji prema ekonomskoj literaturi imaju mogućnost djelovanja na javnu potrošnju, tj. u svakoj državi postoje neki specifični uvjeti koji mogu imati jednako tako važan utjecaj na učinkovitost kao i neki tipični pokazatelji. Tu se može raditi o nekim zakonskim ili institucionalnim okvirima koji su specifični za svaku pojedinu zemlju ili se radi o nekim drugim uvjetima poput razine povjerenja ili razine zaštite vlasničkih prava. U radu od Slijepčević (2009) regresijska analiza je korištena poslije neparametarske analize omeđivanja podataka, dakle regresijska analiza je poslužila kao dodatna analiza kojom se htio napraviti širi obuhvat mogućih varijabli koje mogu utjecati na učinkovitost javne potrošnje. (Slijepčević, 2009)

Regresijskim modelom izražava se stohastička povezanost između jedne zavisne i jedne ili više nezavisnih varijabli. Zavisna varijabla može se zvati regresand ili endogena varijabla, dok se nezavisne varijable obično nazivaju regresorske ili egzogene varijable. Obično se ova povezanost modelira pomoću sljedećeg linearnog regresijskog modela. (Bahovec, Erjavec, 2009)

$$Y_t = \beta_0 + \beta_1 x_{1t} + \beta_2 x_{2t} + \ldots + \beta_k x_{kt} + \varepsilon_t$$

No u radu Slijepčević (2009) korišten je Tobit regresijski model. Razlog je taj što je u radu uzeta zavisna varijabla čija je vrijednost ograničena za određeni broj vrijednosti. Takav model još se naziva i model latentne zavisne varijable. Tu zavisna varijabla može poprimiti sljedeće vrijednosti.

$$y_i \begin{cases} \underline{c_i} & ako\ je\ y_i * \leq \underline{c_i} \\ y_i * & ako\ je\ \underline{c_i} < y_i * < \overline{c_i} \\ \overline{c_i} & ako\ je\ \overline{c_i} < y_i * \end{cases}$$

Brojevi $\overline{c_i}$ i $\underline{ci}$ su brojevi koji predstavljaju neke proizvoljne vrijednosti unutar kojih se nalazi vrijednost zavisne varijable, dok je y_i* latentna varijabla čije se vrijednosti ne opažaju. Razlog zašto je uzet takav model je u tome što kad zavisna varijabla poprima samo određene

vrijednosti, onda procjene koje se dobiju putem metode najmanjih kvadrata daju pristranog i konzistentnog procjenitelja. Specifičnost kod Tobit modela je ta što se radi o specifičnom modelu u kojem je vrijednost $\overline{c_i}$ = 0. (Slijepčević, 2009)

- **Stohastička analiza granica metoda (eng. Stochoastic Frontier Analysis)**

Sljedeća parametarska metoda je analiza stohastičke funkcije. Iako nije korištena ni u radu Bogovića (2014), ni Slijepčević (2006), svakako je potrebno proučiti značaj ove analize. Kod analize stohastičke funkcije potrebno je razmotriti više pitanja. Kao prvo nameće se pitanje treba li procijeniti funkciju proizvodnje ili troškova. Ako je svrha određenog istraživanja analiza u razlikama između različitih outputa, onda se treba procijeniti funkcija proizvodnje. No problem nastaje kad postoji situacija gdje određena organizacija proizvodi više različitih vrsta outputa, onda je veoma teško dobiti neki jedinstveni pokazatelj. Zbog toga se češće procjenjuje funkcija troška jer ona dopušta postojanje jedinstvenog pokazatelja. Isto tako, ako se pretpostavi da u nekoj određenoj organizaciji postoji postupak minimizacije troškova, onda možemo dobiti funkciju troškova koja je identična proizvodnoj funkciji, no to je veoma teško za pretpostaviti kod svake organizacije, kao na primjer u zdravstvu. Osim toga postavlja se pitanje transformacije podataka s kojima određeni istraživač raspolaže. Jer ako se podaci ne transformiraju, onda se pretpostavlja linearan odnos između varijabli. To bi na primjeru bolnice značilo da je svaki dodatni pacijent jednako doprinio porastu troškova. To naravno nije slučaj u stvarnosti jer obično su granični troškovi veći od prosječnih, posebno kad se radi o opadajućim prinosima na razmjer. Zbog toga će biti potrebno logaritmirati vrijednosti, pa će interpretacija dobivenih koeficijenta biti izražena kroz prosječnu promjenu, odnosno kao elastičnost.

Što se tiče izbora između ukupne ili prosječne vrijednosti, obično se odabire procjena prosječne funkcije zbog problema heteroskedastičnosti, gdje varijanca reziduala ε_i nije konstantna. Pa kako se procijenjene vrijednosti ne bi nalazile daleko od regresijske linije, onda se uzimaju prosječne vrijednosti. Isto tako problem se može pojaviti kod izbora eksplanatornih varijabli. Tu se mogu pojaviti problemi poput multikolinearnosti i endogenosti zbog čega u analizi treba dobro paziti koje su varijable egzogene i dovoljno dobre za objašnjenje troškova. No naravno, najvažnija stvar kod analize učinkovitosti je odrediti organizaciju ili državu koja je najučinkovitija i koja može služiti ostalima kao primjer najbolje prakse. To se preporučuje preko analize reziduala ε_i. Reziduali obično predstavljaju neku statističku pogrešku ili

neopaženu heterogenost, zbog čega im se ne daje puno na značaju u ekonometrijskoj analizi, no smatra se kako je moguće preko reziduala vidjeti u kojoj mjeri određena jedinica odstupa od one s najboljom praksom. U slučaju troškovne funkcije, ona jedinica čiji su reziduali 0 ima prosječnu učinkovitost. One jedinice koje imaju negativne reziduale imaju učinkovitost koja je iznad prosječne, dok one s pozitivnim rezidualima imaju obrnutu situaciju. To zapravo znači da se učinkovitost može rangirati prema prosječnoj učinkovitosti. Dakle, one jedinice koje se nalaze najviše ispod funkcije troškova, smatraju se najučinkovitijima i one predstavljaju jedinicu s najboljom praksom koja služi ostalima kao primjer prema kojem se trebaju voditi. To se grafički može prikazati na način da prvo procijenimo funkciju troškova putem OLS metode gdje ćemo uočiti jedinicu koja se nalazi najviše ispod funkcije i koja je najučinkovitija, nakon čega bismo procijenili funkciju putem COLS metode koja omogućuje da funkcija troškova prolazi kroz točku koja predstavlja tu najučinkovitiju jedinicu, pri čemu se onda može jasno izmjeriti kolika je razina neučinkovitosti ostalih promatranih jedinica, odnosno koliko odstupa svaka pojedina jedinica od one najučinkovitije.

Slika 4.4 Ilustracija OLS funkcije i COLS granice

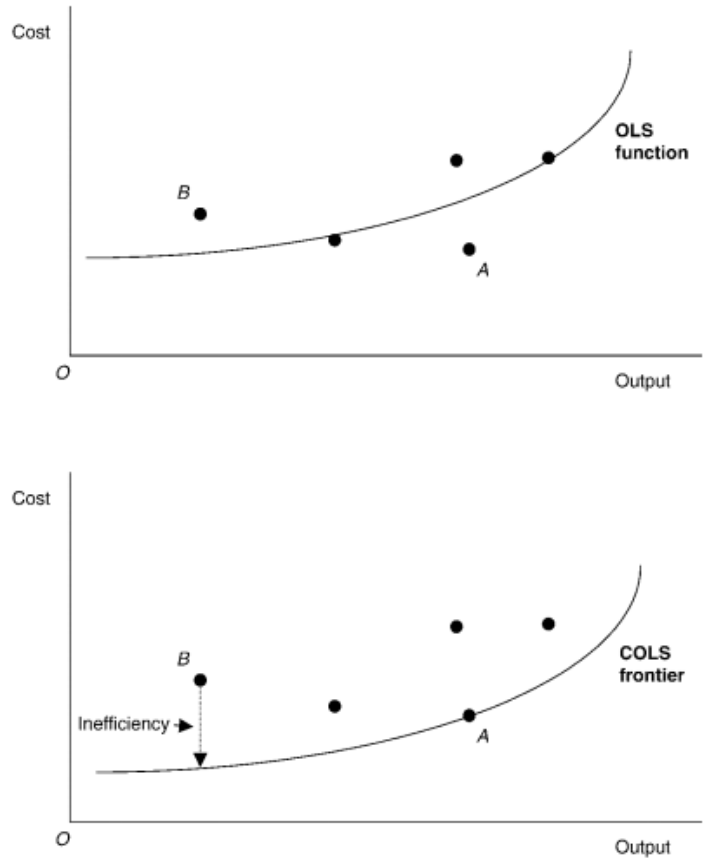

Izvor: Jacobs, Smith i Street (2006).

Naravno, postoji i alternativno objašnjenje koje tvrdi kako je postojanje rezidualnih pogrešaka primarno uzrokovano zbog pogrešaka u mjerenju ili zbog nekih slučajnih događaja. Upravo je radi toga razvijena ekonometrijska tehnika analize stohastičke funkcije kako bi se mogle procijeniti obje komponente rezidualnih pogreški. Dakle, prema metodi analize stohastičke funkcije procjena rezidualne pogreške temelji se na zasebnoj procjeni komponente u_i koja mjeri neučinkovitost i komponente v_i koja mjeri neke slučajne događaje, kao što je prikazano formulom.

$\varepsilon_i = v_i + u_i$

Krivulja dobivena takvom procjenom više ne prolazi kroz točku koja označava jedinicu koja ima najbolju praksu što se može vidjeti na slici 5. Razlog je upravo u tom uključivanju komponente koja mjeri grešku u mjerenju ili neki slučajni događaj. Za preciznu procjenu stohastičke granice potrebno je specificirati distribuciju obje komponente. Tu se obično pretpostavlja da je komponenta u_i normalno distribuirana sa srednjom vrijednošću 0 i konstantnom varijancom, $v_i \sim N(0, \sigma_i^2)$. Distribucija za v_i komponentnu mora se procjenjivati indirektno i u ovisnosti o tome kako se odredi distribucija komponente v_i ovisi koje se jedinice smatraju učinkovitima, a koje ne. (Jacobs, Smith i Street, 2006)

Slika 4.5 Stohastička funkcija

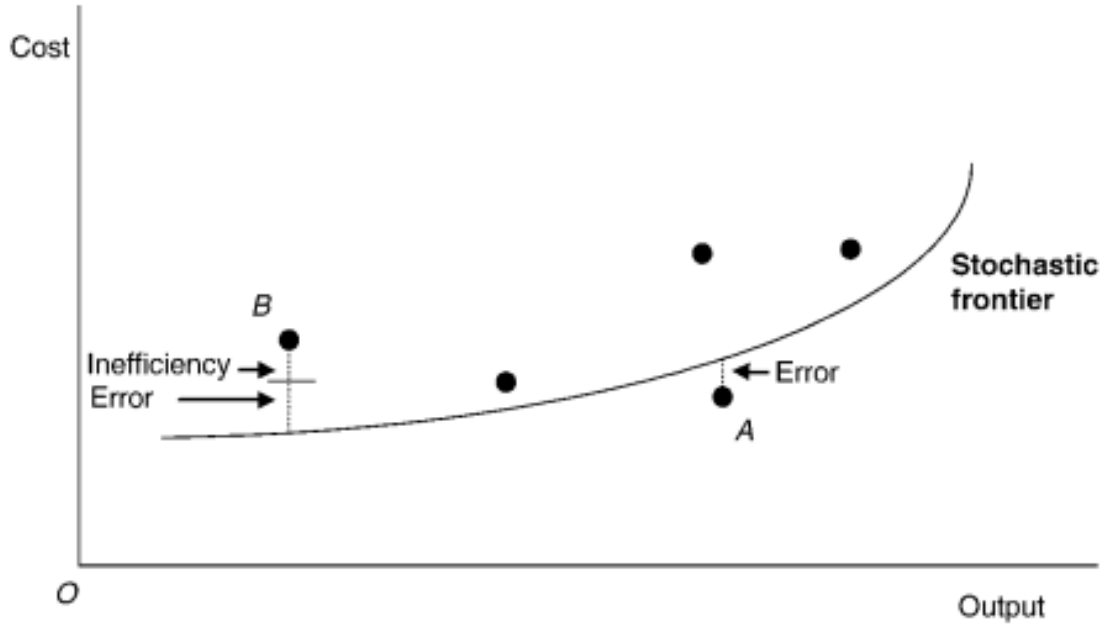

Izvor: Jacobs, Smith i Street (2006).

4.2.3. Neparametarske metode

Kao što je ranije navedeno, razvoj kvantitativnih metoda za mjerenje učinkovitosti temelji se na Farrelovim pretpostavkama o tehničkoj, cjenovnoj i ukupnoj učinkovitosti. Prema Farrelu (1957) učinkovitost se može mjeriti kroz mjerenje učinkovitosti iskorištavanja inputa (*input-oriented efficiency*) ili kroz mjerenje učinkovitosti postizanja outputa (*output-oriented efficiency*).

Kod modela koji mjeri učinkovitost korištenja inputa Farrel (1957) polazi se od dva inputa s kojima je moguće proizvesti jedan output, uz pretpostavku konstantnih prinosa. S tim da je oblik funkcije učinkovite proizvodnje poznat. To je na slici 6. krivulja SS i sva poduzeća koja se nalaze na toj krivulji smatraju se tehnički (proizvodno) učinkovitima, dok ona koja su iznad krivulje nisu učinkovita. Na primjer poduzeće Q, koje koristi jednak omjer inputa kao i poduzeće P, isti output postiže uz manju količinu inputa. Tako da P može postići tehničku učinkovitost na način da proporcionalno smanji količinu inputa kako bi došla na razinu outputa na kojoj se nalazi tehnički učinkovito poduzeće Q. Na grafu je to udaljenost PQ i ona se računa kao omjer udaljenosti točke Q i udaljenosti točke P od ishodišta.

Slika 4.6 Mjerenje učinkovitosti korištenja inputa

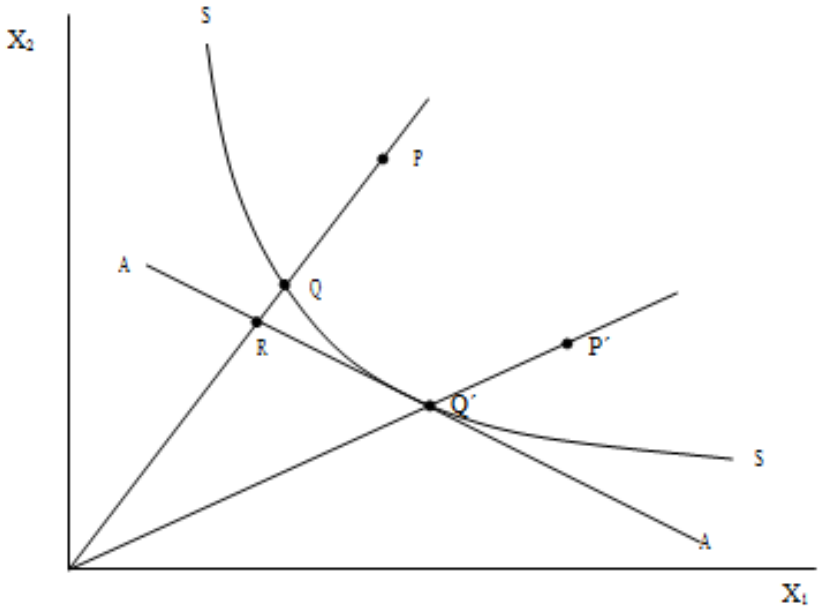

Izvor: Farrell (1957).

Linija AA označava budžetski pravac i njom se mjeri alokativna učinkovitost. Linija predstavlja odnos cijena inputa i ono poduzeće koje se nalazi na toj liniji postiže troškovnu učinkovitost jer je tu granična stopa supstitucije između dva inputa jednaka omjeru njihovih cijena. Tu je poduzeće Q' troškovno učinkovitije od poduzeća Q unatoč činjenici što oba poduzeća postižu tehničku učinkovitost. Grafički je to udaljenost QR koja označava smanjenje proizvodnih troškova koje poduzeće Q treba postići ako želi biti na razini troškovno učinkovitog poduzeća Q'. Ovo se isto može izračunati i to kao omjer udaljenosti točke R i udaljenosti točke Q od ishodišta. Osim ovoga postoji još i ukupna učinkovitost koja se promatra kao omjer te dvije prethodno navedene učinkovitosti. (Jacobs, Smith i Street, 2006; Slijepčević, 2009; Bogović, 2014)

Slika 4.7 Mjerenje učinkovitosti korištenja outputa

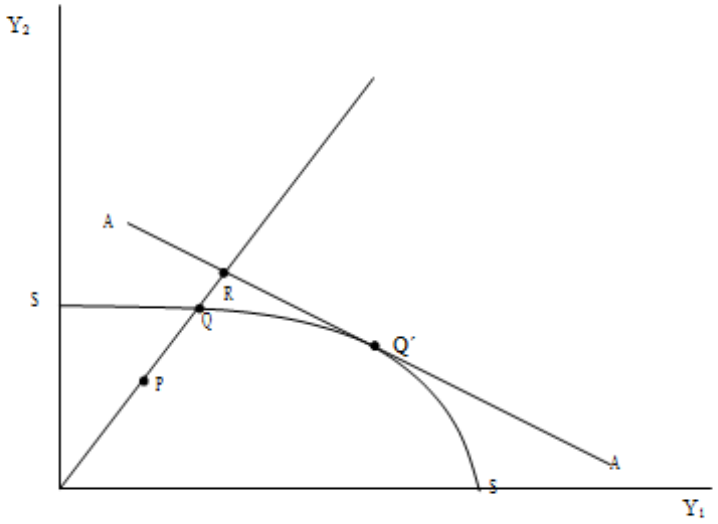

Izvor: Farrell (1957).

Osim mjerenja učinkovitosti inputa može s mjeriti i učinkovitost outputa. Tu imamo mogućnost ostvarivanja dvije različite razine outputa uz korištenje jednog inputa. Kao i u prošlom slučaju imamo krivulju proizvodne učinkovitosti označenu kao SS na slici 7. i sva poduzeća koja su na njoj su tehnički učinkovita, dok ona poduzeća koja se nalaze ispod krivulje su neučinkovita. Dakle, poduzeće P može proporcionalno povećati svoj output uz istu razinu inputa. Pravac AA označava tržišnu vrijednost dva outputa i poduzeće Q' koje se nalazi na pravcu je alokativno učinkovito. Postupak računanja je sličan kao i u prethodnom slučaju. Tehnička učinkovitost se

računa kao omjer udaljenosti točke P i točke Q od ishodišta, grafički je to udaljenost QP. Alokativna učinkovitost se računa kao omjer udaljenosti točke Q i udaljenosti točke R od ishodišta, grafički je to udaljenost QR, a ukupna učinkovitost je umnožak ova dva omjera gdje se gleda koliko je moguće povećati ukupne rezultate uz fiksnu razinu utrošenih resursa. (Jacobs, Smith i Street, 2006; Slijepčević, 2009; Bogović)

- **Analiza omeđivanja podataka (eng. Data Envelopment Analysis)**

Analizu omeđivanja podataka (*Data envelopment analysis*) razvili su Charnes, Cooper i Rhodes (1978) na temelju Farrelovih prethodno navedenih pretpostavki. Metoda se temelji na linearnom programiranju gdje se uspoređuje učinkovitost više homogenih jedinica. Homogenih u smislu da koriste podjednake inpute i da imaju sličnu vrstu otuputa. A pod jedinice se misli na neku organizaciju koja ima kontrolu nad razinom inputa koji se koristi u proizvodnji određenog outputa i obično se naziva jedinica za donošenje odluka (*decision making unit*). Tom usporedbom moguće je odrediti najuspješniju jedinicu koja služi kao primjer nabolje prakse i koja se nalazi na granici učinkovitosti. Nakon toga mjeri se učinkovitost neke druge jedinice i gleda se kolika je njezina neučinkovitost, odnosno koliko je udaljena od jedinice koja se nalazi na granici učinkovitosti. Cilj ovo postupka je naravno izmjeriti koliko neka neučinkovita jedinica može povećati svoj output uz danu količinu inputa ili zadržati istu razinu outputa uz manju količinu inputa. Dakle, prema Jacobs, Smith i Street (2006) sama analiza sastoji se od dva koraka, a to je da se u prvom koraku odredi granica učinkovitosti tako da se odrede one jedinice koje imaju najbolju kombinaciju inputa i outputa. U drugom se koraku za svaku jedinicu izračunava stupanj učinkovitosti tako što se uspoređuje omjer outputa i inputa neučinkovite jedinice s omjerom učinkovite jedinice. To možemo prikazati i primjerom.

Tablica 4-6 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.

Pretpostavimo kako imamo 8 jedinica koje koriste jedan input (ulaz) i proizvode jedan output (izlaz), kao što je prikazano u tablici 7. Sad se putem CCR modela analize omeđivanja podataka može svakoj neučinkovitoj jedinici može pridružiti referentni partner (*benchmarking*), tj. izračunava se razina neučinkovitosti.

Tablica 4-7 Rezultati CCR učinkovitosti

DO	A	B	C	D	E	F	G	H
Učinkovitost *(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.

Kao što se vidi iz tablice 4.7., jedino je jedinica B učinkovita i ona ostalima služi kao primjer najbolje prakse. Ovo se može prikazati i grafički gdje se konstruira granica učinkovitosti na kojoj se nalazi točka B, dok se druge jedinice nalaze ispod granice učinkovitosti. Granica učinkovitosti označava maksimalnu razinu outputa koju svaka jedinica može postići uz danu razinu inputa, tzv. omeđivanje outputa „odozgo“. Tu se svaka jedinica analizira na način da se gleda koliko svaka jedinica odstupa od granice učinkovitosti, uzimajući u obzir vrijednosti outputa drugih jedinica. Pogledajmo na slici 8. na primjer točku C, čija relativna učinkovitost iznosi 0,667, to znači kako ta jedinica može smanjiti količinu iskorištenih inputa s 3 na 2 (3*0,667=2) ili može povećati svoj output s 2 na 3 (2*0,667=3).

Slika 4.8 Grafički prikaz primjera AOMP

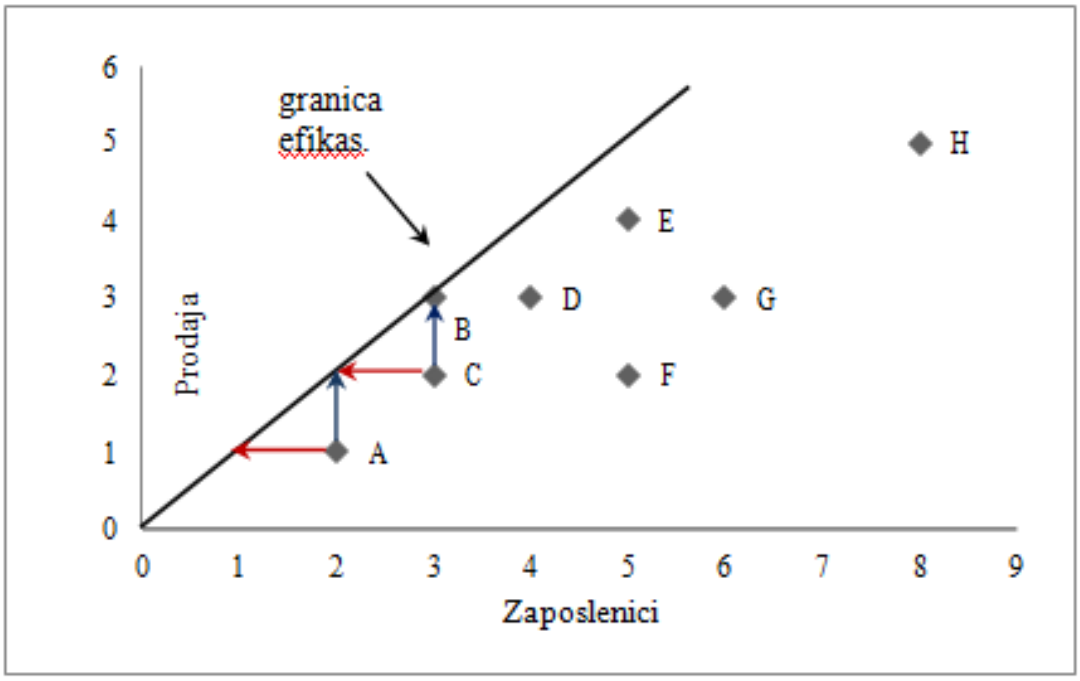

Izvor: Bogović (2014).

Tu treba napomenuti kako je ova granica učinkovitosti napravljena u odnosu na jedinicu koja u danom skupu ima najveću razinu učinkovitosti i da to nikako ne znači da je to najveća moguća učinkovitost koja se može ostvariti. (Bogović, 2014; Slijepčević, 2009; Jacobs, Smith i Street, 2006).

Kod analize omeđivanja podataka postoji više modela, kao i nekoliko elemenata koje treba odrediti prije same analize. U modelu CCR (Charles, Cooper i Rhodes) pretpostavlja se postojanje konstantnih prinosa na obujam (CRS). Tu, kao kod prethodno prikazanog slučaja, one jedinice koje su učinkovite, predstavljaju granicu proizvodnih mogućnosti, odnosno granicu učinkovitosti. Ovaj je model najčešće korišten model i rezultati koji su njime dobiveni označavaju ukupnu tehničku učinkovitost, dok se za dobivanje čiste tehničke učinkovitosti koristi BCC model. Taj model pretpostavlja varijabilnu stopu prinosa, gdje oni mogu biti rastući ili opadajući. Kod varijabilne stope prinosa važno je odrediti je li cilj minimizacija inputa ili maksimizacija outputa. Dakle, proporcionalnom promjenom inputa dolazi do više ili manje proporcionalnog povećanja outputa. Sada granica učinkovitosti više nije pravac, nego je konveksna krivulja. Razliku između ta dva modela je moguće prikazati slikom 4.9.

Slika 4.9 Granica učinkovitosti prema CCR (CRS) i BCC (VRS) modelu

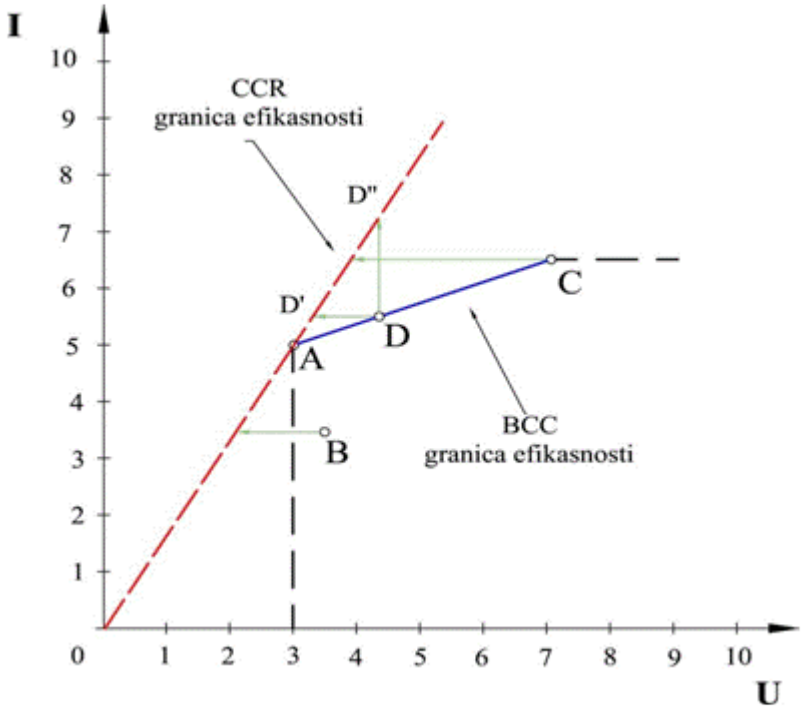

Izvor: Bogović (2014).

Vidimo dakle kako je korištenjem konstantnih prinosa samo jedinica A učinkovita, no ako pretpostavimo varijabilne prinose, onda jedinice D i C isto tako postaju učinkovite jer za razliku od konstantnih prinosa, varijabilni prinosi dopuštaju različite prinose na obujam. Dakle, može se zaključiti kako je korištenjem varijabilnih prinosa učinkovitost uvijek manja ili jednaka onoj koja bi postojala ako se pretpostavi postojanje konstantnih prinosa. (Bogović, 2014; Slijepčević: 2009)

Osim ova dva modela postoji i model prozora. On se koristi u dinamičnoj analizi gdje se u različitim razdobljima različita jedinica identificira kao ona s najboljom praksom i ona u tom razdoblju tvori granicu učinkovitosti. Tu dakle u jednom razdoblju neka jedinica može biti ona koja ima najbolju praksu, dok u sljedećem razdoblju ta ista jedinica više ne mora biti ona najučinkovitija. Ova vrsta analize omogućuje praćenje učinkovitosti tijekom nekog perioda kako bi se vidjela dinamika same učinkovitosti. (Bogović, 2014)

Svi ovi modeli mogu biti usmjereni na ostvarivanje učinkovitosti u korištenju inputa (ulazno usmjereni) ili učinkovitosti u korištenju outputa (izlazno usmjereni). Kod ulazne usmjerenosti, neučinkovita je svaka ona jedinica u kojoj je moguće postići jednaku razinu outputa uz

smanjenje trenutne količine iskorištenih inputa. Kod izlazne usmjerenosti neučinkovita je svaka ona jedinica gdje se mogu ostvariti veće razine outputa uz danu razinu inputa. (Savić i Marić, 2009) O ostalim pitanjima vezanim za AOMP, više će biti riječi kasnije u radu.

- **Free Disposal Hull**

Free Disposable Hull je druga neparametarska metoda koju ćemo analizirati. Ova metoda isto omogućuje mjerenje granice proizvodnje. Za polaznu se pretpostavku uzima da je y_i pokazatelj rezultata određene aktivnosti ili stanja, a inputi koji označavaju rashode te aktivnosti su označeni kao x_i. Za primjer uzimamo pet država koje postižu različite rezultate s različitom razinom rashoda, gdje imamo samo jedan input i jedan output. Onda vidimo, kao što je prikazano u tablici 8., kako zemlje imaju različite kombinacije rezultata i troškova. Na osnovu tih podataka korištenjem FDH metode moguće je konstruirati granicu učinkovitosti i vidjeti koje se zemlje nalaze na granici, a koje ne. Treba napomenuti kako ova metoda ne pretpostavlja nikakav oblik funkcije proizvodnje.

Tablica 4-8 Primjer izračuna učinkovitosti u modelu jedan input - jedan output

Država	Pokazatelj	Rashod
A	40	200
B	75	350
C	90	500
D	110	1.000
E	60	1.300

Izvor: Slijepčević (2009).

Vidimo dakle kako su prema FDH metodi države A, B, C i D na granici učinkovitosti, a samo je država E neučinkovita. Sad je na osnovi te granice učinkovitosti i točke E učinkovitost moguće mjeriti putem vertikalne udaljenosti ili horizontalne udaljenosti. Vertikalnom udaljenošću mjeri se razlika između one ostvarene i one učinkovite razine outputa koji se mogao ostvariti da su se resursi koristili optimalno. Horizontalnom udaljenošću mjeri se razlika između iskorištene razine inputa i one koja omogućuje postizanje učinkovite razine outputa uz manju količinu inputa. Ovu metodu moguće je provesti i u slučaju veće količine inputa i outputa.

Slika 4.10 Primjer određivanja granice učinkovitosti metodom *Free Disposable Hull*

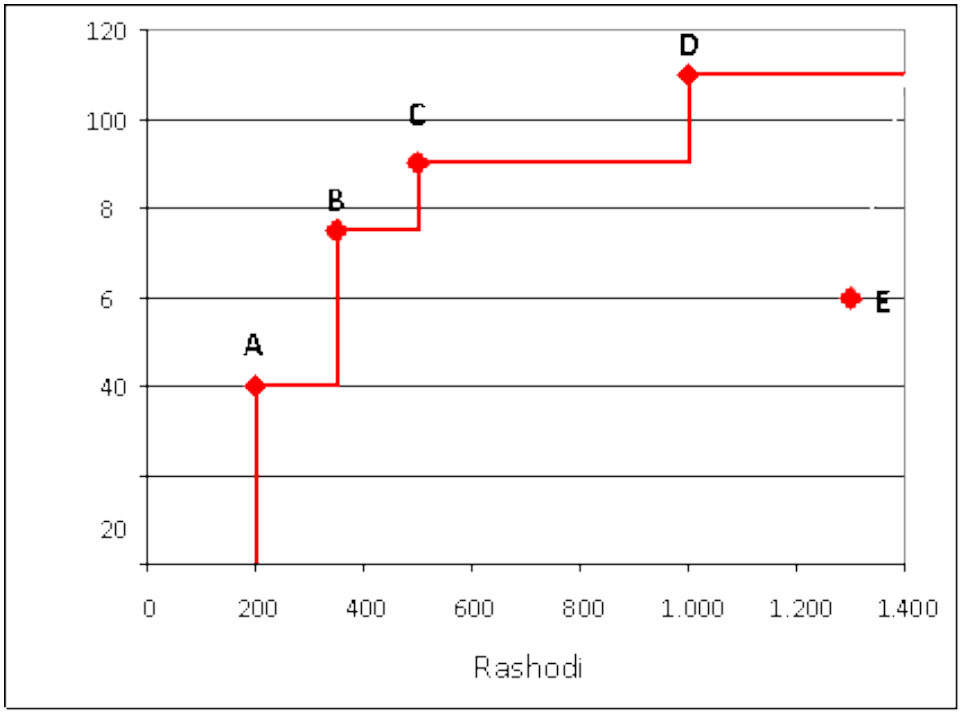

Izvor: Slijepčević (2009).

Treba napomenuti kako se ovdje radi o relativnoj učinkovitosti gdje se za svaku neučinkovitu zemlju traži neka zemlja koja ima bolji odnos utrošenih inputa na dobiveni output, a ako takve zemlje nema, onda se promatrana država smatra učinkovitom. (Slijepčević, 2009)

4.2.4. Mjerenje ostvarenih rezultata (pokazatelji učinkovitosti)

Ovaj dio rada bavit će se pregledom rezultata analize učinkovitosti javnog sektora na državnoj i lokalnoj razini dobivenih na temelju radova Slijepčević (2009) i Bogović (2014). Odnosno prikazat će se rezultati koji su dobiveni korištenjem prethodno navedenih metoda.

Slijepčević (2009) u svojem radu procjenjuje učinkovitosti javne potrošnje kroz usporedbu Hrvatske i 27 zemalja EU-a u razdoblju od 1997. do 2006. godine. Prvo se izmjeri učinkovitost putem analize omeđivanja podataka uz pretpostavku konstantnih i varijabilnih prinosa na obujam, da bi se nakon toga provela i regresijska analiza iz razloga jer se želi uključiti i utjecaj vanjskih čimbenika na učinkovitost javne potrošnje. Analiza omeđivanja podataka omogućuje usporedbu razine učinkovitosti koju postiže Hrvatska u odnosu na ostale članice EU-a pri čemu se onda može konstruirati granica učinkovitosti koja omogućuje analizu koja ukazuje na to

koliko Hrvatska odstupa od optimalne razine javne potrošnje. Sama analiza orijentirana je na dva aspekta javne potrošnje. S jedne strane se proučavaju osnovne funkcije javne potrošnje, dok se s druge strane mjere rezultati države u određenim područjima javne potrošnje. Kao temeljne funkcije uzete su funkcije stabilizacije, distribucije i alokacije. Za područja javne potrošnje uzeti su pokazatelji za javnu upravu, javni red i sigurnost, socijalnu zaštitu, obranu, obrazovanje i zdravstvo. Sve to omogućuje izračun rezultata učinkovitosti javnog sektora, i to na način da se prvo proučava uspješnost svake pojedinačne funkcije ili područja, te se onda na osnovi njih formira kompozitni pokazatelj kojim se onda može vršiti usporedba između Hrvatske i ostalih zemalja EU-a. Upravo taj kompozitni pokazatelj služi kao output u analizi mjerenja učinkovitosti putem AOMP metode, a on je potreban iz razloga jer se koristi model jedan input – jedan output, gdje je input udio rashoda opće države u BDP-u. (Slijepčević, 2009)

Bogović (2014) isto tako mjeri učinkovitost javne potrošnje, ali na razini 15 velikih gradova u RH, bez uključivanja grada Zagreba, putem analize omeđivanja podataka. Uzeta su dva modela: CCR model koji pretpostavlja konstantne prinose na obujam i BBC model koji pretpostavlja varijabilne prinose na obujam. Za proučavanje vremenske dinamike odabrana je analiza prozora. Za inpute su uzeta dva diskrecijska inputa koji su pod kontrolom lokalne uprave: porez i prirez na dohodak, te komunalni doprinos i druge naknade. I dva nediskrecijska inputa nad kojima lokalna uprava nema kontrolu: prosječan broj radno aktivnog stanovništva (RAS) i dohodak po stanovniku. Za output su uzete sljedeće varijable: stopa nezaposlenosti, prosječne plaće i investicijski potencijal (investicije u gospodarstvu po zaposlenom). A za odgovor na istraživačko pitanje koje istražuje povezanost učinkovitosti upravljanja s razinom ekonomske razinom ekonomske razvijenosti koristit će se dva indikatora: indeks razvijenosti i indeks ekonomske učinkovitosti gradova Republike Hrvatske. (Bogović, 2014)

- **Interpretacija parametara iz parametarskih metoda**

Od parametarskih metoda, jedino se u radu Slijepčević (2009) koristi regresijska analiza. Ona služi kako bi se analizirao utjecaj nekih vanjskih učinaka na koje država može, a i ne mora imati utjecaja. U radu je korišten Tobit regresijski model gdje zavisna varijabla može poprimiti sljedeće vrijednosti.

$$Učinkovitost\ javne\ potrošnje \begin{cases} 0\ za\ potpuno\ neučinkovitu\ javnu\ potrošnju \\ između\ 0\ i\ 1\ za\ relativnu\ neučinkovitost\ javne\ potrošnje \\ 1\ za\ potpunu\ učinkovitost\ javne\ potrošnje \end{cases}$$

Kao varijable koje mogu imati utjecaj na učinkovitost javne potrošnje uzete su: BDP *per capita,* pokazatelj vlasničkih para, stupanj vanjskotrgovinske razmjene, stupanj transparentnosti javnog sektora, stopa pismenosti stanovništva, udio stanovništva starijeg od 65 godina u ukupnom stanovništvu, udio javnih rashoda za zdravstvo u ukupnim rashodima za zdravstvo te stupanj povjerenja u političare. Za odabrane varijable specificiran je sljedeći model,

učinkovitost postizanja outputa = β_1 * BDP_{pc} + β_2 * vlasnicka_prava + β_3 * stopa_pismenosti + β_4 * otvorenost_gospodarstva + β_5 * povjerenje + β_6 * transparentnost + β_7 * udio_starijih_ od_65 + β_8 * javni_rashodi_za_zdravstvo + ε. No ipak se ovaj model nije mogao koristiti u analizi jer se izračunom korelacijske matrice uvidjelo kako postoji korelacija između pojedinih nezavisnih varijabli radi čega se nije provela analiza na prethodnom modelu, nego je specificirano sedam različitih modela.

Rezultati tih sedam modela ukazuju na činjenicu da stopa pismenosti, udio javnih rashoda u ukupnim rashodima za zdravstvo, stupanj zaštite vlasničkih para te BDP *per capita* mogu djelomično objasniti neučinkovitosti javne potrošnje. (Slijepčević, 2009)

- **Interpretacija parametara iz neparametarskih metoda**

Za mjerenje učinkovitosti javne potrošnje u radu Slijepčević (2009) putem neparametarskih metoda uzeta je analiza omeđivanja podataka uz pretpostavku konstantnih i varijabilnih prinosa na obujam. Kod „strože“ pretpostavke konstantnih prinosa Hrvatska je po razini učinkovitosti u usporedbi s ostalim zemljama EU na predzadnjem mjestu. Ona ostvaruje relativnu učinkovitost od samo 56,8 %. RH je dakle mogla imati samo 56,8 % od one javne potrošnje koju je imala u promatranom razdoblju i opet bi ostvarivala isti output. Ako se uzme da su u tome razdoblju prosječni rashodi opće države bili oko 48,1 % BDP-a, to bi značilo da je mogla postići jednake rezultate da su rashodi bili samo 27,4 % BDP-a, tek onda bi mogla imati jednaku razinu učinkovitosti kao Irska koja se nalazi na granici učinkovitosti, odnosno uz zadržavanje postojeće razine potrošnje, trebalo bi povećati output za 43,2% kako bi dosegla Irsku.

Kod pretpostavke varijabilnih prinosa analiza je napravljena i za minimizaciju inputa, kao i za maksimizaciju outputa. Dakle, uz pretpostavku varijabilnih prinosa i minimizacije inputa

Hrvatska ima učinkovitosti od 70,4% i nalazi se na 22. od ukupno 28. mjesta. Kako bi ostvarivala jednaku razinu outputa, treba smanjiti javnu potrošnju za 29,6% što bi značilo da je prosječno u promatranom razdoblju trebala imati javnu potrošnju od samo 33,9% BDP-a. Isto tako uz pretpostavku varijabilnih prinosa, analizom se uvidjelo kako se Hrvatska nalazi u području opadajuće stope prinosa, dakle svako povećanje inputa za 1 jedinicu rezultira povećanjem outputa za manje od te jedne jedinice. A ako se uzme kao pretpostavka maksimizacija outputa, onda Hrvatska ostvaruju učinkovitost od 70,4% što znači da bi uz zadržavanje jednake razine potrošnje trebala povećati output za 29,6%. Tu se Hrvatska nalazi na 25. od 28. mjesta. Dakle, prema dobivenim rezultatima javna potrošnja u Hrvatskoj je neučinkovita, stoga bi Hrvatska trebala ili smanjiti razinu potrošnje ili povećati output uz danu razinu potrošnje kako bi postala učinkovita. (Slijepčević, 2009)

Mjerenje učinkovitosti u radu Bogovića (2014) dalo je sljedeće rezultate. Prvo se analizira model koji promatra samo diskrecijske inpute i tri outputa. CCR modelom, koji pretpostavlja konstantne prinose, dobila se prosječna relativna učinkovitost od 87,7%, što pokazuje da grad može jednake rezultate postići koristeći samo 87,7% resursa, odnosno da može postići jednake rezultate ako smanji razinu inputa za 13,3%. BCC modelom, koji pretpostavlja varijabilne prinose, učinkovitost iznosi 91,4%. Na temelju oba modela ispalo je da je šest promatranih gradova učinkovito i da oni čine granicu učinkovitosti, te služe kao uzor ostalim neučinkovitim gradovima. Kao učinkoviti gradovi navode se: Dubrovnik, Pula, Slavonski Brod, Varaždin, Velika Gorica i Vinkovci. Kao najveći izvor neučinkovitosti navodi se stopa nezaposlenosti i to je posebno izraženo kod 6 gradova: Bjelovar, Karlovac, Osijek, Samobor, Split i Zadar. Isto tako veliki utjecaj na neučinkovitost ima output investicije po zaposlenom i on je jako značajan kod Siska i Šibenika.

Nakon toga je napravljena analiza prozora. Tu se u razdoblju od 2005. do 2008. promatra vremenska dimenzija učinkovitosti. Dakle, odabrana su četiri prozora koji traju po godinu dana. Analizom se dobilo da ni jedan grad nije bio učinkovit 2005. i 2008. godine, dok je 2006. učinkovito bilo njih šest, a 2007. jedan. S tim da najveću učinkovitost pokazuje grad Varaždin, a najmanju Samobor.

Zatim se analiziraju nediskrecijski inputi čiji se rezultati uspoređuju s onim dobivenim kad su se analizirali samo diskrecijski inputi. Analizom je dobiveno da su svi gradovi, osim Vinkovaca, koji su bili učinkoviti u analizi s diskrecijskim inputima, ostali učinkoviti i kod analize nediskrecijskih inputa. Dakle, iako postoji mala promjena granice učinkovitosti, dva rezultata pokazuju visoku razinu korelacije.

Što se tiče usporedbe s indeksima razvijenosti i ekonomske učinkovitosti, rezultati pokazuju da indeks razvijenosti ne pokazuje nikakvu povezanost s relativnom učinkovitošću upravljanja gradom kad se promatraju samo diskrecijski inputi, dok povezanost postoji kod nediskrecijskih inputa. Isti rezultat dobiven je i za drugi indeks. Dakle, može se zaključiti kako učinkovitost samih gradova primarno ovisi o sposobnostima gradskih vlasti. (Bogović, 2014).

4.3. Rasprava i analiza prednosti i nedostataka alternativnih metoda mjerenja učinkovitosti

U ovom dijelu rada analizirat će se dodatna pitanja, posebno nedostaci kod prethodno navedenih metoda. Posebna pažnja posvetit će se analizi omeđivanja podataka pošto je to oblik analize koji je najčešće korišten u radovima. Nakon toga će se navesti još neki alternativni načini mjerenja učinkovitosti, posebno na lokalnoj razini koji mogu donositeljima odluka pomoći u svakodnevnim odlukama.

Što se tiče *cost benefit* i *cost effectiveness* analize, posebno se ističe nekoliko problema o kojima je već prije bilo riječi. Na primjer problem mjerenja troškova i koristi u smislu nemogućnosti izražavanja istih u novčanom iznosu – to je veoma čest slučaj u mnogim društvenim djelatnostima gdje se, primjerice, oportunitetni trošak obrazovanja teško može izraziti novčano. Nadalje, postoji problem neopipljivih koristi, kao na primjer korist od obrazovanijeg stanovništva. Osim toga tu je i već navedeni problem diskontne stope, gdje se posebno ističe problem visine same stope, što je detaljnije prikazano u tablici 4.9.

Tablica 4-9 Posljedica odabira kamatne stope

Diskontna stopa kod javnih projekata	Sektorski poremećaji	Poremećaji koji nastaju u vremenu
Preniska	U javnom se sektoru ulaže previše resursa u odnosu na privatni sektor.	U dugoročne projekte ulaže se previše resursa u odnosu na kratkoročne projekte.
Previsoka	U javnom se sektoru ulaže premalo resursa u odnosu na privatni sektor	U kratkoročne projekte ulaže se previše resursa u odnosu na dugoročne projekte.

Izvor: Brümmerhoff (1997)

Isto tako veoma se često u *cost benefit* analizi ne može izabrati između više različitih ciljeva, odnosno ne može se odrediti koji cilj je važniji od onih drugih. Kod *cost effectiveness* analize imamo problem da se u nekim područjima, kao u zdravstvu ili okolišu, ne mogu jasno odrediti ciljevi, kao i činjenica da nekad postoji više mogućih ciljeva. Svi ovi problemi osnovnih analitičkih metoda doveli su do razvoja kvantitativnih metoda kojima se htjelo riješiti ove probleme. (Slijepčević, 2009)

Kvantitativne metode koje su nastale na temelju Farrelovih pretpostavki dijele se na parametarske i neparametarske. Kao dobar prikaz osnovnih razlika među njima možemo se poslužiti tablicom 10. koja prikazuje razlike između jedne parametarske i jedne neparametarske metode čime se zapravo mogu vidjeti prednosti i nedostaci ovih metoda.

Što se tiče analize omeđivanja podataka, postoje još neki problemi koje je potrebno spomenuti. U analizi omeđivanja podataka moguće je uvesti određene pondere, no to je u praksi veoma teško jer se postavlja pitanje na koji se način može odrediti važnost jednog inputa ili outputa naspram drugog. Osim toga odluke o važnosti u javnom su sektoru primarno u domeni političara.

Tablica 4-10 Usporedba temeljnih karakteristika između metode analize omeđivanja podataka i stohastičke funkcije troška

Karakteristika	Analiza omeđivanja podataka	Stohastička funkcija troška
Pretpostavka o obliku funkcije	Ne.	Da, snažna.
Razdvaja slučajnu grešku od promjene učinkovitosti	Ne.	Da.
Testira uvođenje nove varijable u model	Ne.	Nesavršeno.
Dopušta egzogene faktore	Da.	Da.
Dopušta mogućnost analize učinkovitosti u situaciji kad se ostvaruje više outputa	Da.	Ne.
Daje informacije o parici (engl. *peer DMU*)	Da.	Ne automatski.
Model je osjetljiv na netipične, odnosno ekstremne vrijednosti (engl. *outlier*)	Da.	Djelomično. Moguće je provesti dodatno testiranje.
Multikolinearnost	Ne.	Da, može se testirati.
Problem endogenosti	Da.	Da, može se testirati.
Heteroskedastičnost	Ne.	Da, može se testirati.
Model nije primjeren za male uzorke	Djelomično. Zavisi o pretpostavkama modela i broju varijabli uključenih u analizu učinkovitosti.	Da.

Izvor: Jacobs, Smith i Street (2006).

Jednako tako može se postaviti pitanje mjeri li se Farrelova ili Koopmansova učinkovitost gdje Koopmans pri konstruiranju granice učinkovitosti uvodi puno stože kriterije oko toga koje

točke smiju činiti tu granicu, no ni to pitanje nije do kraja razriješeno, stoga odluka o tome koje će točke biti uključene ovisi o samom istraživaču. (Farrel, 1957; Koopmans, 1951)

No jedno od ključnih ograničenja metode AOMP je subjektivnost svakoga istraživača u odabiru koje će inpute i outpute koristiti u analizi. To je posebno problem kad nije u potpunosti jasno koji su inputi i u kojoj su mjeri utjecali na određeni output. Isto tako problem je ograničen broj inputa koji se uzima u analizi, jer u nijednoj analizi nije moguće uzeti sve moguće inpute koji mogu utjecati na neki output. Od ostalih problema može se navesti činjenica da rezultat jako ovisi o specifikaciji modela, da su moguće pogreške u mjerenju inputa i outputa radi čega nečija učinkovitost može biti precijenjena. Onda se navodi kako broj jedinica uključenih u model treba biti barem tri puta veći od broja inputa i outputa. Treba isto paziti na homogenost svih jedinica da se ne bi dogodilo da neka jedinica ne koristi neki input koji druge koriste, zbog čega ta jedinica odmah postaje učinkovita jer ne koristi ništa od tog inputa. I kao posljednji problem može se navesti utjecaj vanjskih čimbenika na učinkovitost, gdje se onda primjenjuje kombinacija matematičkih i statističkih metoda kako bi se i oni mogli obuhvatiti. (Slijepčević, 2009; Bogović, 2014)

Nakon analize prethodnih metoda moguće je navesti još tri dodatne metode koje omogućuju mjerenje ostvarenih učinaka na lokalnoj, operativnoj razini vlasti.

Kao prva metoda navodi se model uravnoteženih ciljeva ili BSC model (*Balanced Scorecard*). On je razvijen u privatnom sektoru i omogućuje da se vizija i strategija nekog poduzeća pretvori u određene operativne mjere. Odnosno cilj neke organizacije želi se učiniti jasnijim i na taj način učinkovitije upravljanim. Na razini javne uprave postoje četiri perspektive. Prva je odnos s klijentima, odnosno korisnicima javnih usluga. Tu se gleda kako poboljšati odnos s građanima, i razumjeti što građani od njih žele. Radi toga se mogu kreirati određeni indikatori s kojima će se pratiti napredak javne uprave. Sljedeća je financijska perspektiva. Ovo je jako važna perspektiva jer sve druge perspektive ovise o njoj. Ona dakle predstavlja određeno ograničenje javnoj upravi i podsjeća ju na nužnost smanjenja troškova. Treća je perspektiva internih procesa. Ona se temelji na poticanju nekih inovacija koje će doprinijeti povećanju kvalitete usluga koje pruža javna uprava kao i smanjenju troškova zbog čega ova perspektiva nadopunjuje onu financijsku. Posljednja je perspektiva učenje i rast. Tu je naglasak na ljudskim potencijalima same javne uprave, te stvaranje bolje radne atmosfere kako bi se poboljšale

performanse same uprave. BSC metoda se smatra odličnom za mjerenje učinkovitosti pojedinih organizacija iz javnog sektora, no problem je što je veoma teško pratiti sve uzročno-posljedične veze svih nabrojanih aktivnosti. (Bogović, 2014; Niven, 2002)

Sljedeća metoda je Europski model poslovne izvrsnosti (EFQM). Ona se temelji na upitniku koji određenoj profitnoj ili neprofitnoj organizaciji pruža mogućnost podizanja samosvijesti o tome koliko je sama organizacija uspješna u svojem poslovanju. Sam upitnik ispunjavaju ljudi unutar i izvan organizacije. On je podijeljen na dio koji se naziva aktivatori koji organizaciji daje sliku o tome kako se rade određene stvari unutar same organizacije i na dio koji mjeri postignute rezultate. Nakon što se riješi upitnik, organizacija može uvidjeti kolika je imala poboljšanja u određenom području. Zasada je EFQM model u Hrvatskoj slabo zaživio. (Bogović, 2014)

Zadnji model koji može pomoći djelatnicima lokalne samouprave je CAF ili zajednički okvir za ocjenjivanje. On je izgrađen na temelju EFQM-a i isto tako služi za samoocjenjivanje javne uprave. Isto je izrađen kao upitnik, no prednost mu je što jasno identificira jake i slabe točke određene organizacije. Isto tako može doprinijeti zbližavanju čitave organizacije jer u samoocjenjivanju sudjeluje cijela organizacija. A kao ključna prednost je to što je izrađen baš za javnu upravu i omogućuje lakšu usporedbu s onima koji imaju najbolju praksu. (Bogović, 2014).

5. EMPIRIJSKI MODEL ZA OCJENU UČINKOVITOSTI UPRAVLJANJA NEKRETNINAMA U HRVATSKIM GRADOVIMA

Ovo poglavlje predstavlja središnje empirijsko poglavlje doktorske disertacije. U njemu se definira konceptualni okvir istraživanja, definiraju se i opisuju varijable te se predstavljaju odgovarajući empirijski modeli analize. Prvo će se definirati odabrani DEA model, koji se temelji na output metodi, s varijabilnim prinosima. Nakon toga se definira poseban oblik panel modela, Tobit model, čija se specifičnost očituje u ograničenoj vrijednosti zavisne varijable (u slučaju ovog rada zavisna varijabla, pokazatelj učinkovitosti upravljanja nekretninama u gradovima, poprima vrijednost između 0 i 1). Konačno, u ovom poglavlju se interpretiraju rezultati empirijske analize u kontekstu postavljenih istraživačkih hipoteza.

Zbog boljeg razumijevanja odabranog analitičkog pristupa u ovoj disertaciji na Slici 5.1. je prikazan konceptualni model istraživanja.

Slika 5.1 Konceptualni model istraživanja

Prikupljanje, obrada i deskriptivna analiza javno dostupnih podataka iz baza različitih institucija: Državni zavod za statistiku, Financijska agencija, Ministarstvo financija, Hrvatski zavod za zapošljavanje, Državna revizija.

↓

DEA analiza
input – vrijednost nekretnina po stanovniku
output – prihodi od nekretnina po stanovniku

Izračun pokazatelja efikasnosti θ

↓

Uključivanje pokazatelja učinkovitosti θ u panel Tobit analizu

$$\theta_{it}^{*} = \beta X_{it} + \varepsilon_{it}$$

$$\theta^{*}{}_{it} = \begin{cases} 0 \; if \theta_{it}^{*} \leq 0 \\ 1 \; if \; \theta_{it}^{*} \geq 1 \\ \theta_{it}^{*} \; if \; 0 < \theta_{it}^{*} < 1 \end{cases}$$

θ_{it}^{*} - pokazatelj učinkovitosti upravljanja nekretninama
X_{it} – skup glavnih objašnjavajućih varijabli
β – vektor parametara
Y – vektor parametara
ε_{it} – greške relacije

Izvor: izrada autora

Slika pokazuje kako se analiza u ovom istraživanju provodi u nekoliko koraka. Prvi korak predstavlja prikupljanje, obradu i deskriptivnu analizu podataka iz različitih sekundarnih izvora podataka. U analizi se koriste podaci iz različitih izvora, poput baza podataka i izvještaja Državnog zavoda za statistiku, Fine, Ministarstva financija, Hrvatskog zavoda za zapošljavanje i Državne revizije. Zbog preglednosti ove su varijable podijeljene u nekoliko skupina – varijable koje se koriste u izračunu zavisne varijable, glavne objašnjavajuće varijable u analizi te skup kontrolnih varijabli.

U drugom se koraku korištenjem dviju varijabli, vrijednosti nekretnina po stanovniku (input) te prihoda od nekretnina po stanovniku (output) metodom omeđivanja podataka (DEA) definira središnja varijabla u ovom istraživanju, pokazatelj učinkovitosti upravljanja nekretninama u gradovima. Ova se varijabla u trećem koraku analize uključuje u panel analizu (koja se temelji na panel-Tobit modelu) kao zavisna varijabla, dok ostale varijable imaju ulogu glavnih objašnjavajućih varijabli ili kontrolnih varijabli. Ove su varijable detaljno objašnjene u nastavku.

5.1. Odabir varijabli i izvori podataka

Analiza i istraživanje u ovoj disertaciji provodi se na uzorku od 126 gradova u Republici Hrvatskoj u dvanaestogodišnjem razdoblju od 2005. do 2016. godine. U Republici Hrvatskoj postoji 128 gradova, ali su Kutjevo i Popovača isključeni iz analize u ovoj disertaciji. Uzrok isključenja Grad Kutjeva je zbog nedostatka podataka i grešaka u podacima u proračunu, dok je Grad Popovača isključen iz analize iz razloga što je dobio status Grada u travnju 2013. godine, odnosno u drugoj polovini analiziranog dvanaestogodišnjeg razdoblja. Kako bi se osigurala što veća homogenost uzorka istraživanja, gradovi su u većem dijelu analize[13] segmentirani prema veličini te su podijeljeni u tri skupine: mali gradovi, srednji gradovi i veliki gradovi[14]. Odabir varijabli u ovom istraživanju determiniran je istraživačkim pitanjima i hipotezama, a u nastavku su prikazana osnovna obilježja varijabli koje se u empirijskom dijelu

[13] Analiza se na ukupnom uzorku gradova provodi samo u testiranju hipoteza H3 i H4 budući da je zbog prirode zavisne varijable procjenu modela moguće napraviti samo za cijeli uzorak (H3 – postoji 21 sjedište županije, a sve su sjedišta veliki gradovi pa se ne može procijeniti učinak te varijable na uzorku od 25 velikih gradova; H4 – PRLS model koristi samo mali broj gradova pa je njihov udio u pojedinoj skupini gradova vrlo mali).
[14] Kriteriji za grupiranje gradova objašnjeni su u nastavku teksta.

istraživanja koriste u izračunu zavisne varijable, koje predstavljaju glavne objašnjavajuće varijable te varijabli koje pripadaju skupini kontrolnih varijabli.

5.1.1. Varijable koje se koriste za izračun zavisne varijable

Budući da je fokus ove disertacije na učinkovitosti upravljanja nekretninama, prvo je potrebno definirati varijable na kojima se temelji izračun pokazatelja učinkovitosti. Kako bi se definiralo upravlja li pojedini grad učinkovito nekretninama u svojem vlasništvu, nužno je utvrditi vrijednost tih nekretnina pri čemu vrijednost nekretnina predstavlja vrijednost imovine iskazanoj u bilanci na dan 31.12. pojedine godine, koja spada u skupinu 01 nefinancijska imovina, i pod skupinu 011 Materijalna imovina – prirodna bogatstva, odjeljak 0111 zemljište, te skupinu 02, pod skupinu 21, odjeljak 0211 stambeni objekti i odjeljak 0212 poslovni objekti. Podaci o imovini gradova dostupni su u bazama i izvješćima Državne revizije i Ministarstva financija. Zbog bolje usporedivosti podataka ova je varijabla normalizirana brojem stanovnika, prema podacima Državnog zavoda za statistiku.

Tablica 5.1. prikazuje temeljne pokazatelje deskriptivne statistike varijable *vrijednost nekretnina po stanovniku* za pojedinu skupinu gradova.

Tablica 5-1 Prosječna vrijednost nekretnina po stanovniku u kunama za radzoblje 2005. – 2016. - deskriptivna statistika

	Mali	Srednji	Veliki
Prosjek	10.722	9.657	12.926
Medijan	6.057	4.600	7.145
Standardna devijacija	12.968	14.556	18.459
Minimum	912	531	1.301
Maksimum	64.566	79.203	74.550
Zbroj	621.850	415.265	323.152
Broj	58	43	25

Izvor: izračun autora

Tablica pokazuje kako je prosječna vrijednost nekretnina po stanovniku od 2005. do 2016. godine u skupini malih gradova iznosila 10,5 tisuća kuna, dok je medijan iznosio 6 tisuća kuna po stanovniku, što ukazuje na postojanje ekstremnih vrijednosti, a što potvrđuju i podaci u minimumu i maksimumu koji pokazuju da najmanja vrijednost nekretnina po stanovniku iznosi 912 kuna (Klanjec), a najviša 64,6 tisuća kuna (Nin). Značajne razlike među gradovima u ovoj

skupini se očituju i u relativno visokoj standardnoj devijaciji, tj. prosječnom odstupanju od prosjeka, koje iznosi 12,9 tisuća kuna po stanovniku. Slični zaključci vrijede i u ostalim skupinama gradova. U skupini srednje velikih gradova prosječna vrijednost nekretnina po stanovniku u promatranom je razdoblju iznosila 9,7 tisuća kuna, dok je medijan iznosio 4,6 tisuća kuna. Najmanja vrijednost nekretnina po stanovniku iznosi 531 kunu (Benkovac), a najviša 79,2 tisuće kuna (Crikvenica), uz standardnu devijaciju od 14,6 tisuća kuna po stanovniku. Konačno, u skupini velikih gradova prosječna vrijednost nekretnina po stanovniku u promatranom razdoblju iznosila je 12,9 tisuća kuna, dok je medijan iznosio 7,1 tisuću kuna, uz standardnu devijaciju od 18,5 tisuća kuna po stanovniku. Usporedbom među gradovima može se zaključiti kako su najznačajnije razlike u vrijednosti nekretnina po stanovniku zabilježene u skupini velikih gradova (najveća standardna devijacija), pri čemu ova skupina gradova ima i najveću medijalnu vrijednost nekretnina po stanovniku.

Sljedeća važna varijabla za analizu učinkovitosti upravljanja nekretninama je varijabla koja prikazuje novčani tijek od nekretnina. U ovoj disertaciji se u tu svrhu koriste podaci o prihodima od nekretnina iskazani u proračunima gradova, koji su dostupni na stranicama Ministarstva financija. Konkretno, prihod od nekretnina predstavlja ukupan iznos prihoda iskazanih u izvještaju PR-RAS, funkcijski, razina 22, kojeg čine:

- prihodi imovine (razred 64), prihodi od nefinancijske imovine (pod skupina 642), prihod od zakupa i iznajmljivanja imovine (odjeljak 6422)
- prihodi od prodaje neproizvedene dugotrajne imovine (razred 71), prirodna bogatstva (pod skupina 711), zemljišta (odjeljak 7111)
- prihodi od prodaje proizvedene dugotrajne imovine (razred 72), prihod od prodaje građevinskih objekata (pod skupina 721), stambeni objekti (odjeljak 7211)
- prihodi od prodaje proizvedene dugotrajne imovine (razred 72), prihod od prodaje građevinskih objekata (pod skupina 721), poslovni objekti (odjeljak 7212).

Zbog bolje usporedivosti podataka i ova varijabla je normalizirana brojem stanovnika, prema podacima Državnog zavoda za statistiku. Tablica 5.2. prikazuje temeljne pokazatelje deskriptivne statistike varijable *prihod od nekretnina po stanovniku* za pojedinu skupinu gradova.

Tablica 5-2 Prosječan prihod od nekretnina po stanovniku u kunama za razdoblje 2005. – 20016. - deskriptivna statistika

	Mali	Srednji	Veliki
Prosjek	415	348	383
Medijan	209	239	294
Standardna devijacija	496	420	267
Minimum	7	15	98
Maksimum	2.422	1.955	998
Zbroj	24.062	14.950	9.586
Broj	58	43	25

Izvor: izračun autora

Tablica pokazuje kako je prosječan prihod od nekretnina po stanovniku od 2005. do 2016. godine u skupini malih gradova iznosio 415 kuna, dok je medijan iznosio 209 kuna po stanovniku. Najmanji prihod od nekretnina po stanovniku iznosi 7 kuna (Zlatar), a najviši 2,4 tisuće kuna (Novigrad-Cittanova). Standardna devijacija od 496 kuna po stanovniku ukazuje na značajne razlike među gradovima u ovoj skupini. Slični zaključci vrijede i u ostalim skupinama gradova.

U skupini srednje velikih gradova prosječan prihod od nekretnina po stanovniku u promatranom razdoblju iznosi 348 kuna, dok je medijan iznosio 239 kuna. Najmanji prihod od nekretnina po stanovniku iznosi 15 kuna (Sveta Nedelja), a najviši 420 kuna (Poreč), uz standardnu devijaciju od 420 kuna po stanovniku. Konačno, u skupini velikih gradova prosječan prihod od nekretnina po stanovniku u promatranom razdoblju iznosio je 383 kune, dok je medijan iznosio 294 kune, uz standardnu devijaciju od 267 kuna po stanovniku. Usporedbom među gradovima može se zaključiti da veliki gradovi imaju najviši prosječan prihod od nekretnina po stanovniku, dok su najveće razlike (najveća standardna devijacija) zabilježene u skupini malih gradova.

Navedene dvije varijable u analizi će se koristiti kao input i output DEA modela, na temelju kojeg će se definirati zavisna varijabla u panel analizi. Ovaj postupak bit će detaljno objašnjen u nastavku rada, gdje će se detaljno analizirati i obilježja gradova prema učinkovitosti u upravljanju nekretninama.

5.1.2. Glavne objašnjavajuće varijable

Osim navedenih varijabli, na kojima se temelji izračun zavisne varijable, u empirijskom dijelu disertacije korišten je i niz objašnjavajućih varijabli, tj. potencijalnih odrednica učinkovitosti upravljanja nekretninama u gradovima. Glavne objašnjavajuće varijable u ovom istraživanju su veličina gradova, lokacija gradova, institucionalna funkcija gradova (gradovi sjedišta županija) te implementacija PRLS modela upravljanja imovinom. U nastavku su prikazana temeljna obilježja gradova u uzorku, prema navedenim varijablama. Veličina gradova je definirana prema Zakonu o lokalnoj i područnoj (regionalnoj) samoupravi[15] prema kojem je veliki grad jedinica lokalne samouprave koja je ujedno gospodarsko, financijsko, kulturno, zdravstveno, prometno i znanstveno središte razvitka šireg okruženja i koja ima više od 35.000 stanovnika, srednji grad je onaj s brojem stanovnika između 10.000 i 35.000, a mali grad s brojem stanovnika manjim od 10.000. Prema ovim kriterijima u analizu je uključeno 58 malih, 43 srednje velikih i 25 velikih gradova. U empirijskom dijelu analize je veličina gradova, kao jedna od temeljnih objašnjavajućih varijabli, definirana kao binarna varijabla koja poprima vrijednost 1 za velike gradove, a vrijednost 0 za male i srednje gradove. Gradovi su prema veličini prikazani u Tablici 5.3.

Tablica 5-3 Popis gradova prema veličini

Veličina	Ime grada
Mali	Zlatar, Varaždinske Toplice, Lepoglava, Vrgorac, Vodice, Donja Stubica, Oroslavje, Glina, Ozalj, Drniš, Pregrada, Mursko, Središće, Komiža, Trilj, Čabar, Klanjec, Zabok, Otočac, Pakrac, Vrbovsko, Đurđevac, Stari Grad, Ilok, Čazma, Vrlika, Ludbreg, Skradin, Grubišno Polje, Orahovica, Hrvatska Kostajnica, Rab, Otok, Delnice, Lipik, Slunj, Buzet, Donji Miholjac, Hvar, Kraljevica, Senj, Opuzen, Obrovac, Prelog, Nin, Korčula, Pag, Supetar, Vis, Bakar, Krk, Novi Vinodolski, Biograd na Moru, Novalja, Cres, Buje, Vodnjan, Mali Lošinj, Novigrad-Cittanova
Srednji	Sveta Nedjelja, Petrinja, Sveti Ivan Zelina, Metković, Novi Marof, Imotski, Ivanec, Pleternica, Đakovo, Vrbovec, Ogulin, Novska, Jastrebarsko, Križevci, Duga Resa, Našice, Sinj, Knin, Ivanić-Grad, Kutina, Kastav, Benkovac, Garešnica, Solin, Valpovo, Daruvar, Belišće, Dugo Selo, Nova Gradiška, Makarska, Slatina, Zaprešić, Beli Manastir, Ploče, Županja, Labin, Crikvenica, Omiš, Trogir, Umag, Rovinj, Opatija, Poreč
Veliki	Kaštela, Velika Gorica, Bjelovar, Požega, Gospić, Krapina, Slavonski Brod, Samobor, Vinkovci, Šibenik, Karlovac, Sisak, Čakovec, Zagreb, Osijek, Split, Koprivnica, Vukovar, Virovitica, Zadar, Varaždin, Pazin, Dubrovnik, Pula, Rijeka

Izvor: izrada autora

[15] Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, NN 33/01, 60/01, 129/05, 109/07, 125/08, 36/09, 36/09, 150/11, 144/12, 19/13, 137/15, 123/17

Lokacija gradova također je jedna od glavnih objašnjavajućih varijabli u analizi, pri čemu se pod lokacijom gradova podrazumijeva geografski položaj grada u kontekstu primorskih i kontinentalnih gradova. Lokacije gradova na obali mora predstavljaju oni gradovi koji se svojim rubnim granicama područja nalaze i/ili dodiruju morsku obalu, a izvor podataka za ovu skupinu gradova je Državna geodetska uprava. U empirijskom dijelu analize ova je varijabla definirana kao binarna varijabla, koja poprima vrijednost 1 za gradove uz more i 0 za ostale gradove. U analizu je uključeno ukupno 38 morskih gradova (22 mala, 10 srednjih i 6 velikih gradova). Gradovi koji su klasificirani kao morski gradovi prikazani su u Tablici 5.4.

Tablica 5-4 Morski gradovi

Veličina grada	Ime grada
Mali	Bakar, Biograd na Moru, Cres, Hvar, Korčula, Kraljevica, Krk, Mali Lošinj, Nin, Novalja, Novi Vinodolski, Novigrad-Cittanova, Opuzen, Pag, Rab, Senj, Skradin, Stari Grad, Supetar, Vis, Vodice
Srednji	Crikvenica, Labin, Makarska, Omiš, Opatija, Ploče, Poreč, Rovinj, Trogir, Umag
Veliki	Dubrovnik, Kaštela, Pula, Rijeka, Split, Šibenik

Izvor: izrada autora

Osim veličine i lokacije, u ovoj disertaciji jednu od glavnih objašnjavajućih varijabli predstavlja i institucionalan položaj grada u kontekstu uloge u županiji kojoj pripada. Konkretno, ispituje se imaju li gradovi, koji su ujedno i sjedišta županija, bolje pokazatelje učinkovitosti od ostalih gradova. Uloga gradova u ovom je kontekstu definirana Zakonom o područjima županija, gradova i općina u Republici Hrvatskoj[16]. U empirijskoj analizi ova je varijabla definirana kao binarna varijabla koja poprima vrijednost 1 u slučaju da je grad sjedište županije, a 0 u slučaju da grad nije sjedište županije. Gradovi koji su klasificirani kao sjedišta županija (samo veliki gradovi) prikazani su u Tablici 5.5.

Tablica 5-5 Gradovi sjedišta županija

	Ime grada
Gradovi sjedišta županija	Bjelovar, Čakovec, Dubrovnik, Gospić, Karlovac, Kaštela, Koprivnica, Krapina, Osijek, Pazin, Požega, Rijeka, Sisak, Slavonski Brod, Split, Šibenik, Varaždin, Virovitica, Vukovar, Zadar, Zagreb

Izvor: izrada autora

[16] Zakon o područjima županija, gradova i općina u Republici Hrvatskoj, NN: 86/06, 125/06, 16/07, 95/08, 46/10, 145/10, 37/13, 44/13, 45/13, 110/15

Posljednja varijabla koja pripada skupini glavnih objašnjavajućih varijabli u empirijskom istraživanju definirana je kao binarna varijabla koja poprima vrijednost 1 za gradove koji koriste model upravljanja imovinom nastao u okviru Projekta reforme lokalne samouprave (PRLS) i 0 za ostale gradove. U promatranom je razdoblju ukupno 19 gradova implementiralo PRLS model upravljanja imovinom i to 7 malih, 6 srednjih i 6 velikih gradova. Pritom je važno istaknuti kako se trajanje primjene PRLS modela upravljanja imovinom razlikuje među gradovima.

Tablica 5-6 Gradovi koji su implementirali PRLS model upravljanja imovinom

Veličina grada	Ime grada
Mali	Krk, Rab, Zabok, Supetar, Đurđevac, Otočac, Zlatar
Srednji	Crikvenica, Labin, Nova Gradiška, Umag, Knin, Opatija
Veliki	Karlovac, Osijek, Pula, Virovitica, Gospić, Sisak

Izvor: izrada autora

5.1.3. Skupina kontrolnih varijabli

Osim zavisne i glavnih objašnjavajućih varijabli u empirijskom se istraživanju koristi i skup kontrolnih varijabli, koje uključuju nezaposlenost stanovništva, kao važnog pokazatelja stadija poslovnog ciklusa, broj poduzetnika po stanovniku kao pokazatelja poduzetničke aktivnosti te fiskalni kapacitet koji prikazuje fiskalnu moć pojedinog grada. Kontrolne varijable imaju važnu ulogu u panel analizama jer one procjenjuju učinak važnih obilježja gradova (gospodarska situacija u gradu, snaga poduzetničke aktivnosti u gradu i fiskalni kapaciteta grada) na učinkovitost upravljanja nekretninama i smanjuju mogućnost izostavljanja važnih varijabli iz modela (eng. omitted variable bias). Kada bi se ove varijable izostavile iz analize, utjecaj glavnih objašnjavajućih varijabli mogao bi biti precijenjen.

Tablica 5.7. prikazuje pokazatelj nezaposlenosti stanovništva, definiran kao omjer ukupnog broja nezaposlenih osoba iz baze Hrvatskog zavoda za zapošljavanje i ukupnog broja stanovnika. Ovako definirana varijabla može se smatrati samo aproksimacijom stope nezaposlenosti budući da bi za izračun stope nezaposlenosti bili potrebni podaci o radnoj snazi koji za gradove nisu dostupni.

Tablica 5-7 Prosječna vrijednost pokazatelj nezaposlenosti stanovništva u gradovima za razdoblje 2005. – 2016.

	Mali	Srednji	Veliki
Prosjek	6,7%	7,8%	6,8%
Medijan	6,4%	7,8%	6,2%
Standardna devijacija	2,9%	3,4%	2,0%
Minimum	2,1%	2,8%	3,7%
Maksimum	12,9%	15,4%	10,3%
Broj	58	43	25

Izvor: izračun autora

Podaci u tablici pokazuju kako je u razdoblju od 2005. do 2016. godine prosječna vrijednost pokazatelja nezaposlenosti u malim gradovima iznosila 6,7%, pri čemu je najniža vrijednost iznosila 2,1% (Cres), a najviša 12,9% (Grubišno Polje). U skupini srednje velikih gradova prosječna vrijednost pokazatelja nezaposlenosti bila je nešto viša i iznosila je 7,8%, uz najnižu vrijednost od 2,8% (Umag) i najvišu vrijednost 15,4% (Beli Manastir). U skupini velikih gradova prosječna vrijednost pokazatelja nezaposlenosti bila je slična onoj u malim gradovima te je iznosila 6,8%. Najniža vrijednost pokazatelja nezaposlenosti u ovoj skupini gradova iznosila je 3,7% (Pazin), a najviša 10,3% (Vukovar). Standardne devijacije pokazuju kako prosječno odstupanje od prosjeka u svim skupinama gradova nije značajno visoko.

Kako bi se stekao uvid u adekvatnost ovog pokazatelja kao pokazatelja stadija gospodarskog ciklusa, na Slici 5.2. je prikazano kretanje pokazatelja nezaposlenosti po skupinama gradova i realne stope rasta bruto domaćeg proizvoda (BDP) u Hrvatskoj. Slika pokazuje kako su ovi pokazatelji obrnuto proporcionalni, pri čemu je pokazatelj nezaposlenosti u svim skupinama gradova padao u vrijeme gospodarske ekspanzije prije krize 2008. godine, povećavao se u recesiji od 2009. do 2014. godine te se počeo smanjivati usporedno s oporavkom gospodarske aktivnosti nakon 2015. godine. Ovakva kretanja upućuju na to da odabrani pokazatelj adekvatno odražava kretanja u hrvatskom gospodarstvu.

Slika 5.2 Kretanje pokazatelja nezaposlenosti za razdoblje 2005 – 2016.

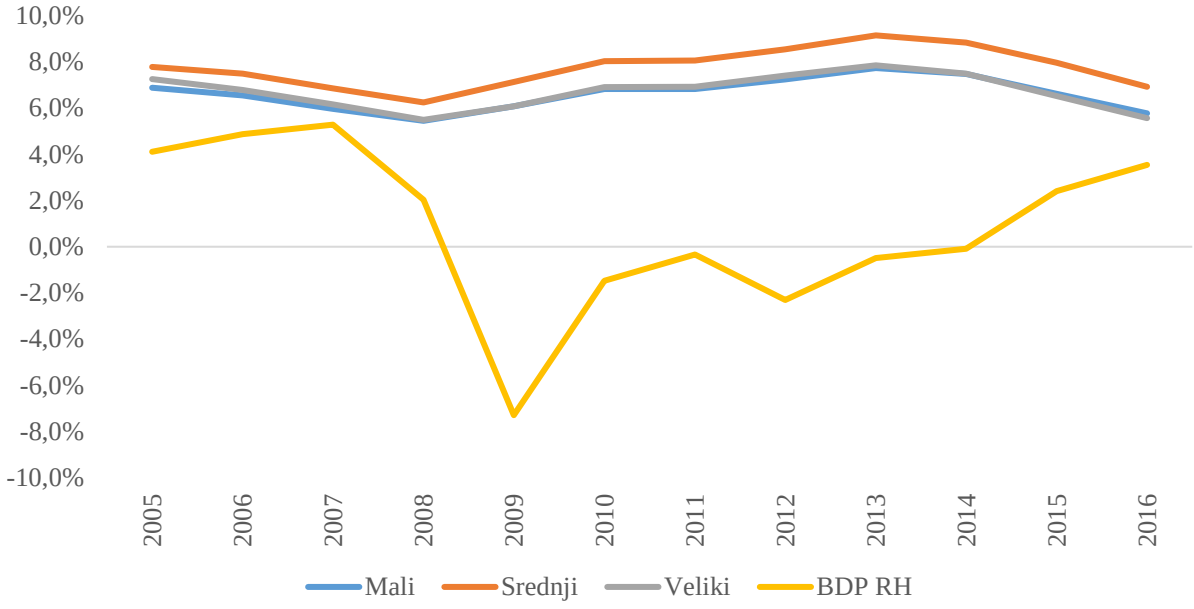

Izvor: izračun autora; Državni zavod za statistiku

Sljedeća kontrolna varijabla koja se koristi u empirijskoj analizi je pokazatelj poduzetničke aktivnosti. Ovaj pokazatelj je izračunat na način da je broj registriranih poduzeća iz baze Fine normaliziran za veličinu grada, pri čemu je indeks koji se koristi za normalizaciju broja poduzetnika izražen u obliku Grad Zagreb = 100. Veća vrijednost indeksa može se interpretirati kao veća gustoća broja poduzetnika s obzirom na broj stanovnika u nekom gradu. Osnovna obilježja navedene varijable po skupinama gradova prikazana su u Tablici 5.8.

Tablica 5-8 Pokazatelj poduzetničke aktivnosti

	Mali	Srednji	Veliki
Prosjek	14,9	15,8	17,9
Medijan	11,3	11,4	14,6
Standardna devijacija	9,7	12,1	7,8
Minimum	3,5	3,8	9,0
Maksimum	55,0	54,6	32,2
Broj	58	43	25

Izvor: izračun autora

Pokazatelj poduzetničke aktivnosti u razdoblju od 2005. do 2016. godine u skupini malih gradova iznosio je 14,9, pri čemu je najmanja vrijednost pokazatelja iznosila 3,5 (Otok), a najviša 55 (Novigrad-Cittanova), što ukazuje na značajne razlike u vrijednosti pokazatelja

unutar skupine gradova. Slični zaključci vrijede i za ostale dvije skupine gradova. Prosječna vrijednost pokazatelja u skupini srednje velikih gradova iznosila je 15,8, uz najmanju vrijednost od 3,8 (Knin) i najvišu vrijednost od 54,6 (Poreč). U skupni velikih gradova prosječan pokazatelj je iznosio 17,9, pri čemu je najniža zabilježena vrijednost 9 (Požega), a najviša 32,2 (Dubrovnik), što ukazuje na manje izražene razlike u vrijednosti ovog pokazatelja u skupini velikih gradova u odnosu na ostale dvije skupine. Usporedba pokazatelja između gradova upućuje kako je poduzetnička aktivnost najjača u velikim gradovima, a najmanja u skupini malih gradova.

Posljednja kontrolna varijabla u analizi je fiskalni kapacitet gradova, koji je izračunat kao odnos ukupnog prihoda poslovanja i broja stanovnika u pojedinom gradu. Izvori podataka za ovaj pokazatelj su Državni zavod za statistiku i Ministarstvo financija. Temeljna obilježja gradova prema ovom pokazatelju prikazana su u Tablici 5.9.

Tablica 5-9 Fiskalni kapacitet gradova

	Mali	Srednji	Veliki
Prosjek	4,020	3,315	4,033
Medijan	3,598	2,678	3,760
Standardna devijacija	1,983	1,814	1,418
Minimum	1,635	1,376	2,291
Maksimum	9,586	8,382	8,143
Broj	58	43	25

Izvor: izračun autora

Podaci u tablici pokazuju kako je u skupini malih gradova fiskalni kapacitet u razdoblju od 2005. do 2016. godine u prosjeku iznosio 4,02 tisuće kuna po stanovniku, uz najmanji fiskalni kapacitet od 1,6 tisuća kuna (Mursko Središće) i najveći od 9,6 tisuća kuna (Novalja). U skupini srednje velikih gradova fiskalni kapacitet bio je nešto niži u odnosu na male gradove, uz prosječan fiskalni kapacitet od 3,3 tisuće kuna po stanovniku te najnižu vrijednost od 1,4 tisuće kuna po stanovniku (Novi Marof) i najveću vrijednost pokazatelja od 8,3 tisuće kuna (Opatija). Veliki su gradovi u prosjeku imali nešto viši fiskalni kapacitet od malih gradova, od 4,03 tisuće kuna, pri čemu je najniži fiskalni kapacitet (2,3 tisuće kuna po stanovniku u Slavonskom Brodu) bio najviši u odnosu na ostale skupine gradova, dok je istovremeno najviši fiskalni kapacitet (8,1 tisuća kuna po stanovniku u Zagrebu) bio manji u odnosu na ostale skupine gradova.

Standardna devijacija pokazuje da je najveća varijabilnost ovog pokazatelja unutar skupine gradova zabilježena u skupini malih gradova.

5.1.4. Popis varijabli korištenih u analizi

Zbog bolje preglednosti varijabli, Prilog 9 Tablica varijabli korištenih u analizi prikazuje nazive, definicije, načine mjerenja te izvore podataka svih varijabli korištenih u analizi.

Vrijednost nekretnina izražava se kao broj koji predstavlja ukupnu vrijednost nekretnina a izvor ovog podataka su financijski izvještaji koje su gradovi predali Ministarstvu financija. Vrijednost nekretnina predstavlja vrijednost imovine iskazanoj u bilanci na dan 31.12., koja spada u skupinu 01 nefinancijska imovina, i pod skupinu 011 Materijalna imovina – prirodna bogatstva, odjeljak 0111 zemljište, te skupinu 02, pod skupinu 21, odjeljak 0211 stambeni objekti i odjeljak 0212 poslovni objekti.

Prihod od nekretnina predstavlja ukupan iznos prihoda iskazanih u izvještaju PR-RAS, funkcijski, razina 22, koje čine:

a) prihodi imovine (razred 64), prihodi od nefinancijske imovine (pod skupina 642), Prihod za zakupa i iznajmljivanja imovine (odjeljak 6422);

b) Prihodi od prodaje neproizvedene dugotrajne imovine (razred 71), prirodna bogatstva (pod skupina 711), Zemljišta (odjeljak 7111);

c) Prihodi od prodaje proizvedene dugotrajne imovine (razred 72), prihod od prodaje građevinskih objekata (pod skupina 721), stambeni objekti (odjeljak 7211);

Prihodi od prodaje proizvedene dugotrajne imovine (razred 72), prihod od prodaje građevinskih objekata (pod skupina 721), poslovni objekti (odjeljak 7212). Iizvor ovog podataka su financijski izvještaji koje su gradovi predali Ministarstvu financija.

Metodom omeđivanja podataka (DEA) izračunati će se pokazatelj učinkovitosti upravljanja nekretninama u gradovima, koji će u radu biti označen kao θ. DEA analiza će se u ovom radu temeljiti na jednom inputu i jednom outputu. Kao input će se koristiti vrijednost nekretnina, a kao output prihodi od nekretnina. Varijabla se izražava kao broj koji predstavlja pokazatelj učinkovitosti a radi se o relativnoj efikasnosti čija se vrijednost nalazi između 0 i 1.

Veličina grada je podatak koji je definiran Zakonom o lokalnoj i područnoj (regionalnoj) samoupravi. Varijabla je definirana kao odabir jedne od tri moguće veličine grada. Veliki je grad je jedinica lokalne samouprave koja je ujedno gospodarsko, financijsko, kulturno, zdravstveno, prometno i znanstveno središte razvitka šireg okruženja i koja ima više od 35.000 stanovnika. Srednji grad je onaj s brojem stanovnika između 10.000 i 35.000, te mali grad s brojem stanovnika manjim od 10.000.

Varijabla Gradovi sjedišta županija definira one jedinice lokalne samouprave koji su sjedišta Županija. Varijabla je definirana kao binarna varijabla, koja će poprimiti vrijednost 1 za gradove sjedišta županija i 0 za ostale gradove. Izvor koji definira ovu varijablu je Zakon o područjima županija, gradova i općina u Republici Hrvatskoj

Varijabla Lokacije gradova, je definirana kao binarna varijabla, koja će poprimiti vrijednost 1 za gradove uz more i 0 za ostale gradove. Lokacije gradova na obali mora predstavljaju one gradovi koji svojim rubnim granicama područja se nalaze i/ili dodiruju morsku obalu.

Varijabla Broj stanovnika, predstavlja ukupan broj stanovnika u pojedinog gradu prema Državnom zavodu za statistiku a odnosi se na procjenu stanovništva po gradovima na 31.12.

Proračunska transparentnost gradova podrazumijeva uvid u potpune, točne, pravovremene i razumljive informacije o proračunu. Varijabla će biti preuzeta iz publikacije i baze podataka Transparentnost proračuna lokalnih jedinica od Instituta za javne financije.

Varijabla Fiskalni kapacitet predstavlja sposobnost gradova da vlastitim proračunskim sredstvima financiraju proračunske rashode. Varijabla se mjeri kao odnos ukupnog prihoda poslovanja i broja stanovnika u pojedinom gradu. Izvor varijable predstavljaju podaci Ministarstva financija i Državni zavod za statistiku.

Broj poduzetnika predstavlja broj aktivnih gospodarskih subjekata koji su u Registar godišnjih financijskih izvještaja dostavili, u roku potpuni i točan godišnji financijski izvještaj na području gradova. Varijabla će se mjeriti aktivnim brojem poduzetnika prema podacima iz registra Fine normaliziranim brojem stanovnika na temelju podataka Državnog zavoda za statistiku, pri čemu je Grad Zagreb=100

Nezaposlenost stanovništva prikazuje koliko je udio stanovništva u pojedinom gradu u promatranoj godini bio nezaposlen. Varijabla se definira kao omjer ukupnog broja nezaposlenih i ukupnog broja stanovnika u pojedinom gradu prema podacima Hrvatskog zavoda za zapošljavanje.

Varijabla PRLS model upravljanja nekretninama, predstavlja paket koje obuhvaća 11 aktivnosti s ciljem postizanja kvalitetnije i učinkovitijeg upravljanju nekretninama u vlasništvu gradova. Varijabla se definira kao binarna varijabla koja poprima vrijednost 1 u gradovima koji primjenjuju PRLS model i 0 u onima koji ga ne primjenjuju. Izvor podataka su baze o gradovima koji su implementirali ovaj model a prikupljene su od Udruge gradova u Republici Hrvatskoj i LIBUSOFT CICOM d.o.o., informatičke i konzultantske tvrtke koja implementira PRLS model.

Nakon što su definirane i analizirane temeljne varijable korištene u analizi, u nastavku rada se definira model za ocjenu učinkovitosti upravljanja nekretninama, na kojem se temelji izračun središnje varijable u disertaciji, pokazatelja učinkovitosti upravljanja nekretninama.

5.2. Definiranje modela za ocjenu učinkovitosti upravljanja nekretninama

U ovom dijelu disertacije detaljno će se objasniti modeli na kojima se temelji empirijsko istraživanje. Prvo će se objasniti metoda omeđivanja podataka (DEA) te će se definirati odgovarajući oblik DEA modela koji se koristi kako bi se izračunao pokazatelj učinkovitosti upravljanja nekretninama u gradovima. Nakon toga će se definirati panel-Tobit model kojim se ispituje utjecaj glavnih objašnjavajućih (i kontrolnih) varijabli na pokazatelj učinkovitosti upravljanja nekretninama u gradovima definiran DEA modelom.

5.2.1. Metoda analize omeđivanja podataka

Analiza učinkovitosti u ovoj disertaciji temelji se na metodi omeđivanja podataka (eng. *data envelopment analysis*, DEA).

Prema Ramanathan (2003) metoda omeđivanja podataka predstavlja tehniku matematičkog programiranja koja ima primjenu u različitim područjima u kojima se mjere performanse sličnih

jedinica promatranja. U slučaju ovog rada jedinice promatranja bit će gradovi u Republici Hrvatskoj. Matematičku formulaciju i naziv metode omeđivanja podataka prvi put su u svojem radu prezentirali Charnes i dr. (1978), pri čemu je važno istaknuti da se DEA analiza koristi za izračun tehničke učinkovitosti koja pokazuje koliko je neka jedinica promatranja učinkovita u alokaciji inputa da bi proizvela željeni output[17]. Tehnička učinkovitost, u kontekstu analize javnih i lokalnih financija, je dostignuta kad se maksimalna razina javnih usluga pruža uz minimalne troškove u smislu utrošenih društvenih resursa u tom procesu.

U nastavku su prikazane osnovne definicije i okvir DEA analize. Slijedeći Ramanathan (2003) pretpostavimo da x_i predstavlja pojedini input, a y_j predstavlja pojedini output u procesu kojim upravlja jedinica promatranja. Ukupan input može se označiti s I, a output s J, pri čemu vrijedi $I, J > 0$ (ukupni inputi i outputi ne mogu imati negativne vrijednosti). U DEA analizi se višestruki input i outputi linearno agregiraju uz pomoć pondera koji predstavljaju ponder pojedinog inputa i outputa u procesu kojim upravlja jedinica promatranja.

Stoga se ukupan input, dobiven putem ponderiranog linearnog zbroja svih inputa može definirati kao:

$$Ukupan\ input = \sum_{i=1}^{I} u_i x_i$$

gdje je u_i ponder za input x_i, koji se koristi pri agregiranju, pri čemu je $u_i \geq 0$.

Slično, ukupan output se može definirati kao:

$$Ukupan\ output = \sum_{j=1}^{j} v_j y_j$$

gdje je u_j ponder za output j, koji se koristi pri agregiranju, pri čemu je $v_j \geq 0$.

Uz tako definirane inpute i outpute učinkovitost pretvaranja inpute u outpute možemo definirati kao:

$$Učinkovitost = \frac{Ukupan\ output}{Ukupan\ input} = \frac{\sum_{j=1}^{j} v_j y_j}{\sum_{i=1}^{I} u_i x_i}$$

U ovako definiranom postupku mjerenja učinkovitosti najveći problem predstavlja odabir adekvatnih pondera za inpute i outpute. U DEA analizi ovaj se problem rješava na način da se

[17] DEA analiza se ne koristi za analizu alokativne učinkovitosti, tj. optimalne alokacije resursa.

svakoj jedinici promatranja dodjeljuju zasebni ponderi za inpute i outpute, koji se temelje na rješenju matematičkog programa u kojem se maksimizira učinkovitost za pojedinu jedinicu promatranja uz ograničenje da se učinkovitost ostalih jedinica promatranja kreće između vrijednosti 0 i 1 (uz pretpostavku istih pondera).

Matematički program može se definirati na sljedeći način. Pretpostavimo da postoji *N* jedinica za koje se uspoređuje učinkovitost. Ako se uzme jedna jedinica promatranja *m* koja maksimizira svoju učinkovitost uz ranije definirano ograničenje učinkovitosti ostalih jedinica, matematički program može se zapisati kao:

$$maxE_m = \frac{\sum_{j=1}^{j} v_{jm} y_{jm}}{\sum_{i=1}^{I} u_{im} x_{im}} \tag{5.1.}$$

tako da

$$0 \leq \frac{\sum_{j=1}^{j} v y_{jn}}{\sum_{i=1}^{I} u_{im} x_{in}} \leq 1; n = 1,2,K,N$$

$$v_{jm}, u_{im} \geq 0; i = 1,2,K,N; j = 1,2,K,J$$

Pri čemu:

E_m predstavlja učinkovitost jedinice odlučivanja *m*

y_{jm} je *j*-ti output jedinice odlučivanja *m*

v_{jm} je ponder tog outputa

x_{im} je *i*-ti input jedinice odlučivanja *m*

u_{im} je ponder tog inputa

y_{jn} i x_{in} predstavljaju *j*-te outpute i *i*-te inpute ostalih *n* jedinica promatranja, *n*=1,2,…N

Za jedinice promatranja za koje DEA pokazatelj poprima vrijednost 1 kaže se da se nalaze na granici (tehničke) učinkovitosti, dok se ostale jedinice promatranja, koje poprimaju vrijednosti manje od 1 do 0, nalaze ispod granice učinkovitosti.

5.2.2. Definiranje ulaza i izlaza za metodu omeđivanja podataka

U ovoj se disertaciji koristi jednostavan DEA model, s jednim inputom i jednim outputom. Kao input varijabla koristi se vrijednost nekretnina u vlasništvu gradova po stanovniku, a kao output prihod od nekretnina po stanovniku u gradovima. Logika ovakvog pristupa temelji se na pretpostavci da gradovi koji učinkovito upravljaju nekretninama u svojem vlasništvu mogu ostvariti značajan prihod od imovine, tj. da mogu ostvariti značajan povrat na imovinu. Važno je istaknuti da se za svaku skupinu gradova računa zaseban DEA model kako bi uzorak analize bio što homogeniji i kako bi rezultati unutar skupine gradova bili usporedivi.

U konkretnom slučaju DEA model korišten u ovoj analizi može se, pojednostavljeno, zapisati kao:

$$maxE_{pojedini\ grad} = \frac{prihod\ od\ nekretnina\ po\ stanovniku\ u\ gradu}{vrijednost\ nekretnina\ po\ stanovniku\ u\ gradu} \qquad (5.2.)$$

tako da

$$0 \leq \frac{prihod\ nekretnina\ po\ stanovniku\ u\ drugim\ gradovima}{vrijednost\ nekretnina\ po\ stanovniku\ u\ drugim\ gradovima} \leq 1$$

Kako bi se DEA pristup dodatno objasnio, na sljedećim slikama je prikazan odnos između inputa (vrijednost nekretnina po stanovniku) i outputa (prihod od nekretnina po stanovniku) zasebno za skupinu malih, srednje velikih i velikih gradova. Podaci predstavljaju prosjek vrijednosti u razdoblju od 2005. do 2016. godine. Sljedeće slike su samo ilustracija koja služi za bolje razumijevanje analitičkog pristupa i ne mogu se koristiti za donošenje čvrstih zaključaka o učinkovitosti upravljanja nekretninama u gradovima. U tu je svrhu provedena DEA analiza, čiji su rezultati prikazani u sljedećem dijelu rada.

Slika 5.3. pokazuje odnos između vrijednosti nekretnina po stanovniku i prihoda od nekretnina po stanovniku u skupini malih gradova. Na slici plava linija predstavlja zamišljenu granicu učinkovitosti koja pokazuje da gradovi koji se na njoj nalaze, uz zadanu razinu vrijednosti nekretnina ostvaruju najviši prihod od nekretnina. Granica učinkovitosti u ovoj je skupini određena s nekoliko gradova (npr. Klanjec, Novalja, Vodnjan, Novigrad-Cittnova), dok se ostali gradovi nalaze ispod nje. Većina gradova koji se nalazi ispod granice ipak nije značajno udaljena od nje, što sugerira da u ovoj skupini gradova učinkovitost ne bi trebala biti preniska,

iako su neki gradovi značajno udaljeni od granice učinkovitosti, poput Nina i Novog Vinodolskog.

Slika 5.3 Odnos vrijednosti i prihoda od nekretnina po stanovniku – mali gradovi

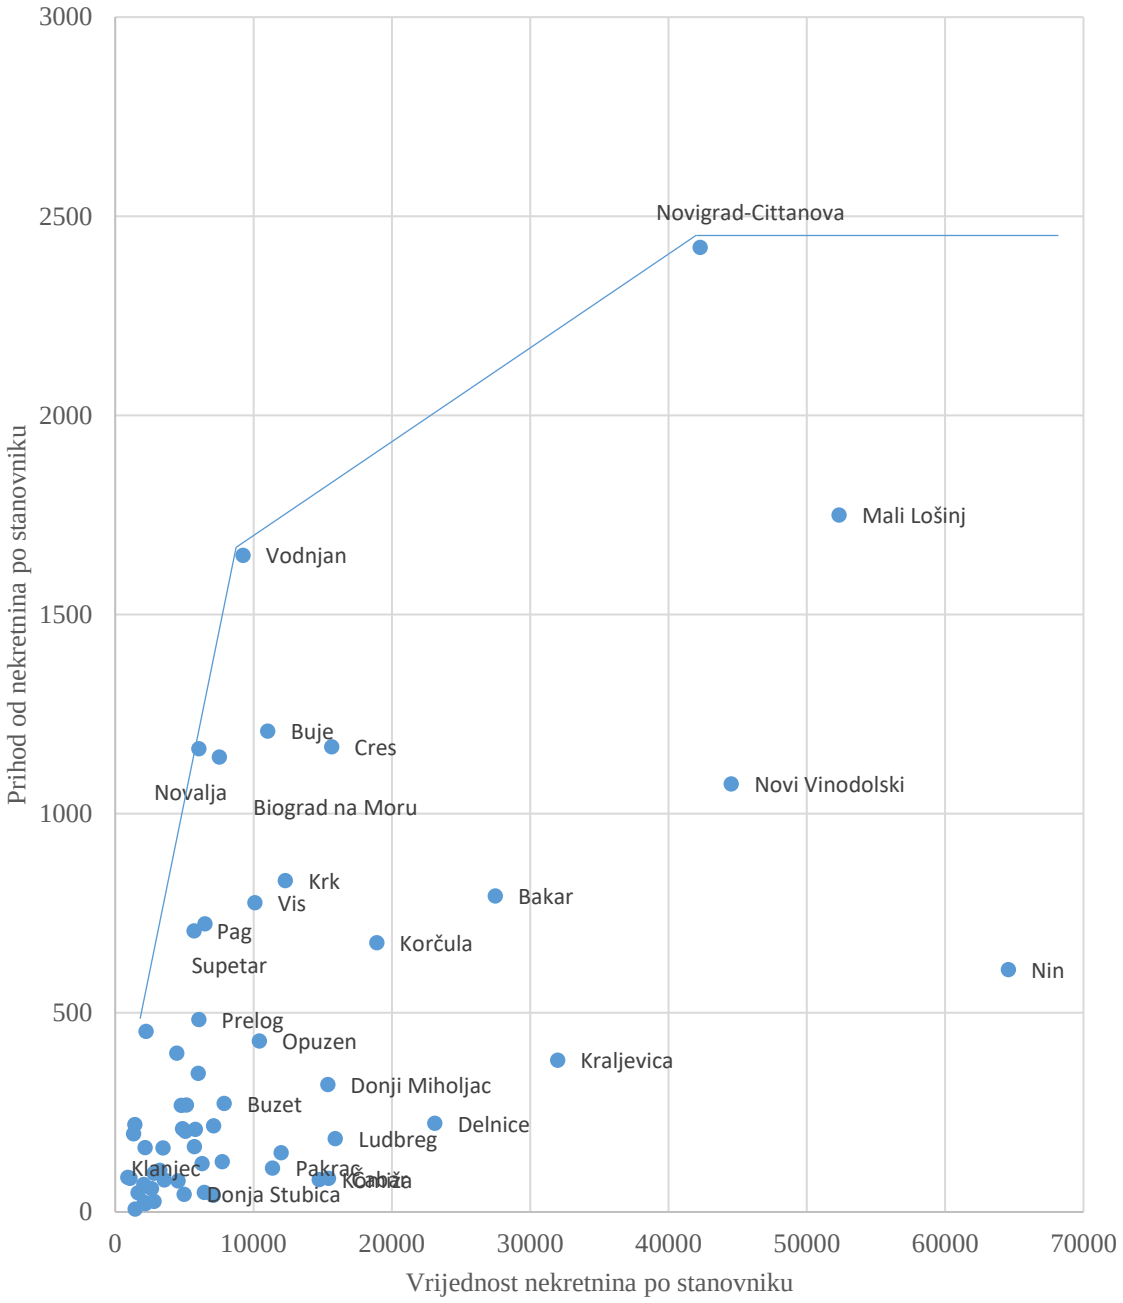

Izvor: izrada autora

Na Slici 5.4.[18] je prikazan isti odnos, ali za skupinu srednje velikih gradova. I u ovoj je skupni gradova granica učinkovitosti određena manjim brojem gradova, poput Benkovca, Omiša,

[18] Budući da slika služi samo kao ilustracija, zbog preglednosti nisu prikazana imena svih gradova.

Opatije i Poreča. Kao i u slučaju malih gradova, najveći broj gradova koji se nalazi ispod granice učinkovitosti nije značajno udaljen od nje, uz pojedine izuzetke poput Crikvenice.

Slika 5.4 Odnos vrijednosti i prihoda od nekretnina po stanovniku – srednje veliki gradovi

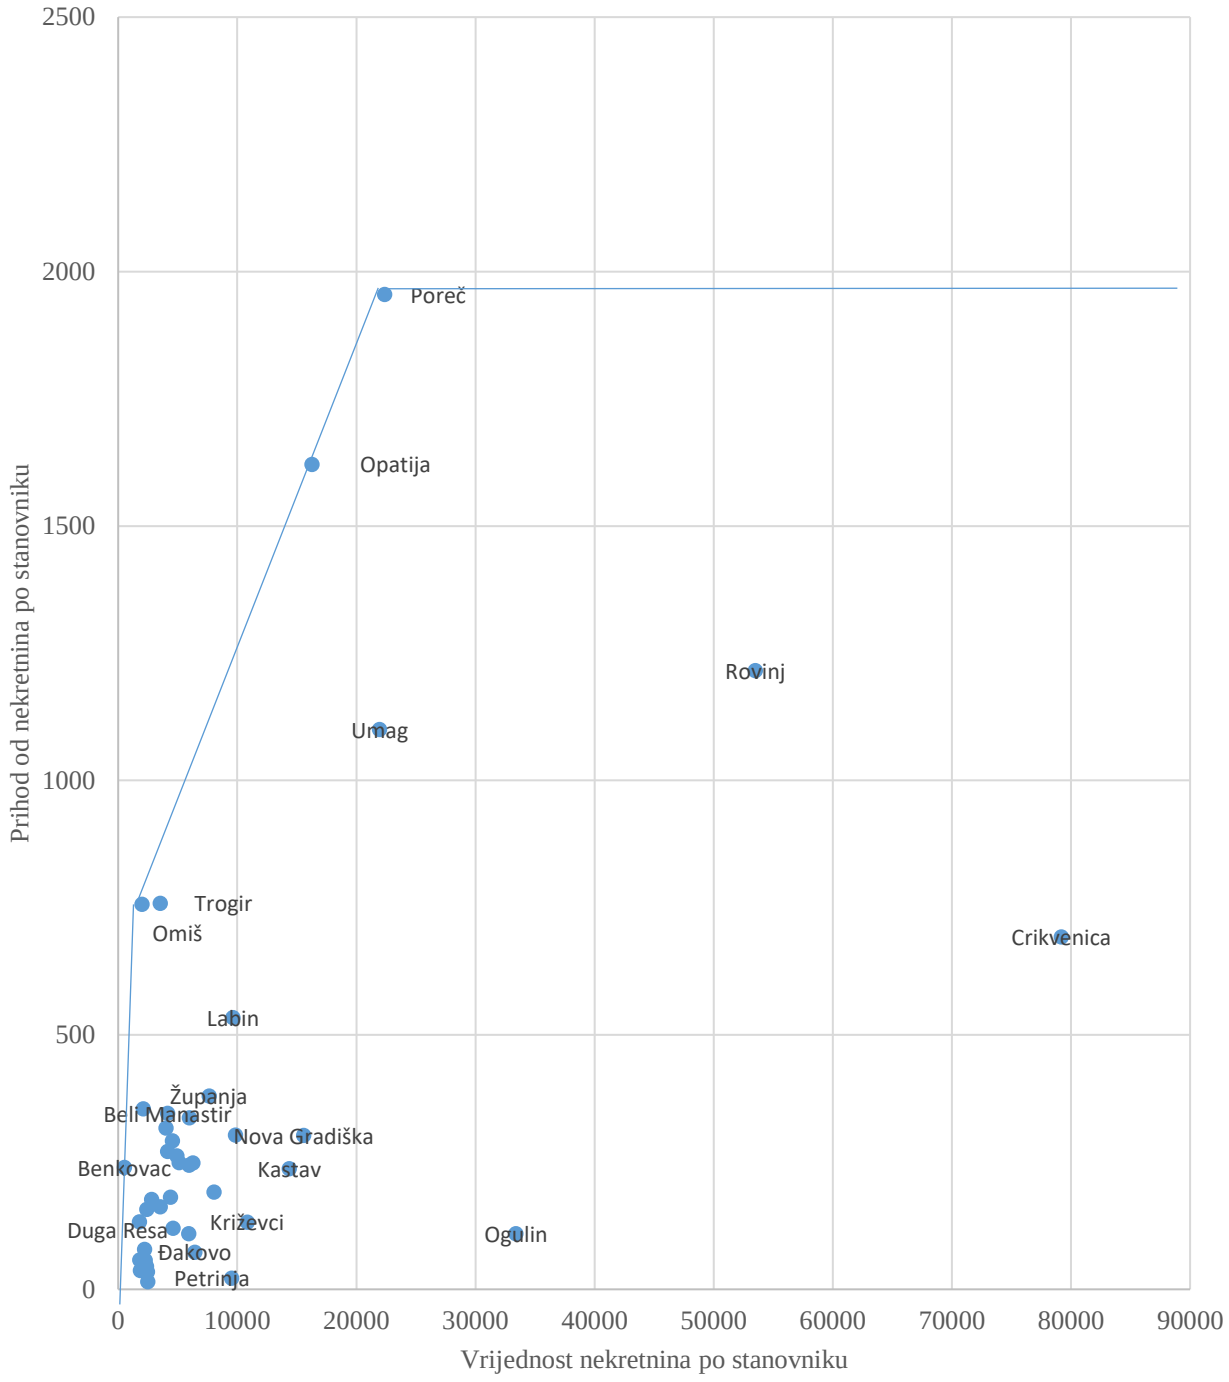

Izvor: izrada autora

Konačno, na Slici 5.5. je odnos vrijednosti nekretnina po stanovniku i prihoda od nekretnina po stanovniku prikazan za skupinu velikih gradova, gdje granicu učinkovitosti, ilustrativno,

određuju Velika Gorica, Pazin i Rijeka, dok, primjerice, Dubrovnik značajnije odstupa od granice učinkovitosti.

Slika 5.5 Odnos vrijednosti i prihoda od nekretnina po stanovniku – veliki gradovi

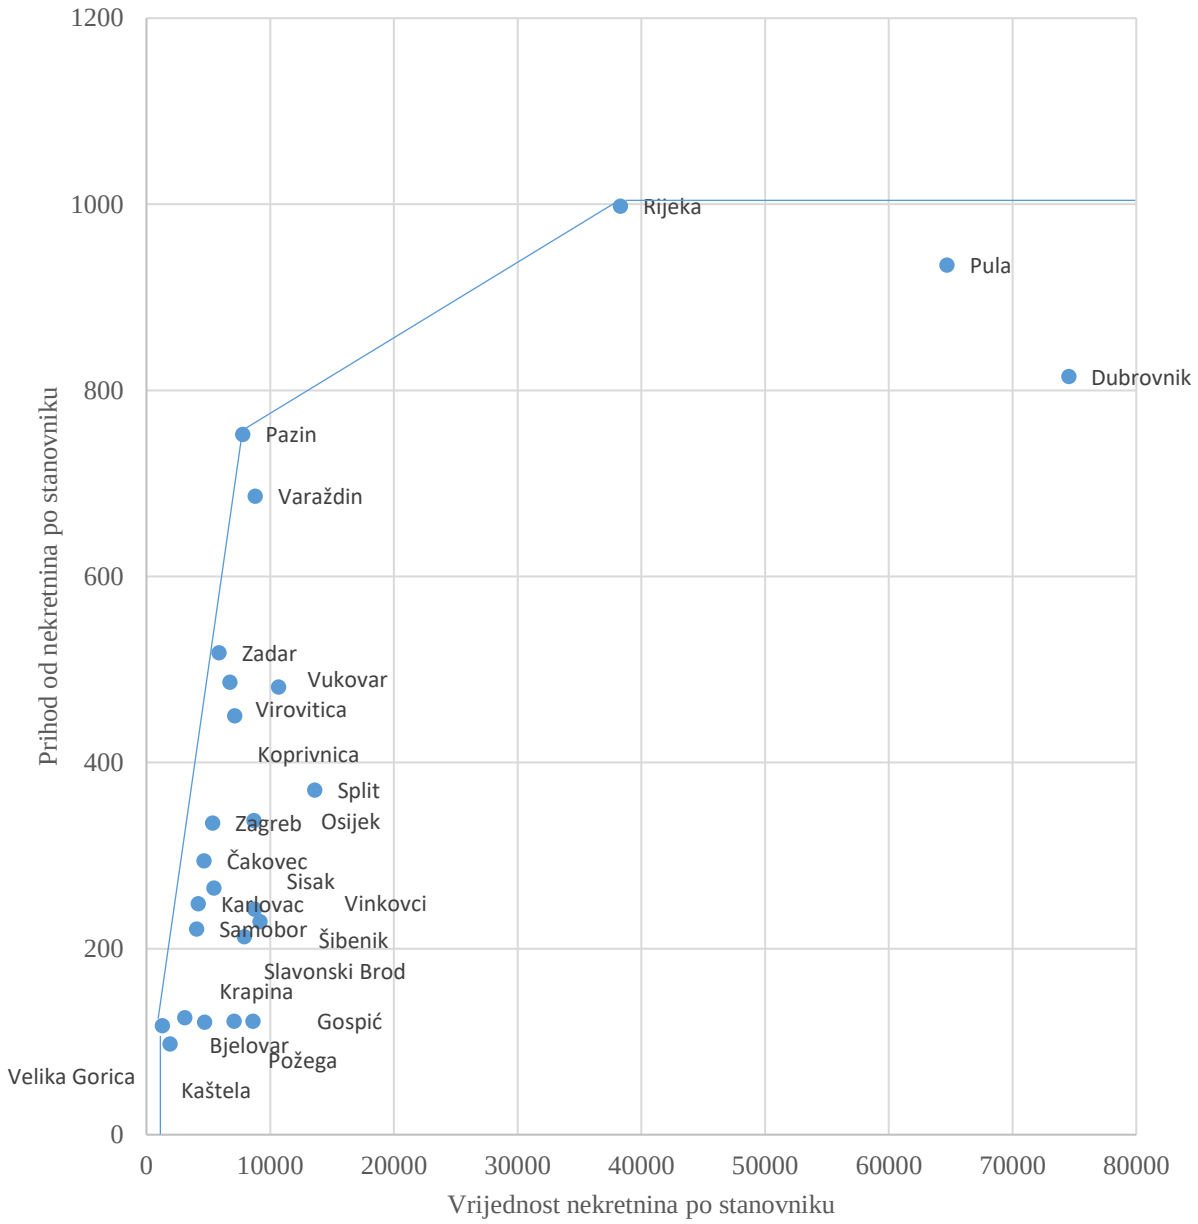

Izvor: izrada autora

Kako bi se precizno i kredibilno utvrdili gradovi koji određuju granicu učinkovitosti i kako bi se odredilo koliko su neki gradovi udaljeni od nje, potrebno je provesti formalnu analizu, za što je potrebno definirati adekvatan DEA model.

5.2.3. Definiranje modela analize omeđivanja podataka

U odabiru adekvatnog DEA modela istraživači moraju donijeti odluku o dva temeljna obilježja modela. Prvo je potrebno donijeti odluku hoće li se koristiti model orijentiran na input (eng. input oriented) ili output (eng. output oriented). Nakon toga je potrebno donijeti odluku hoće li se koristiti pretpostavka konstantnih prinosa (eng. constant returns to scale - CRS) na opseg ili varijabilnih prinosa na opseg (eng. variable returns to scale - VRS).

Odabir orijentacije modela najviše ovisi o istraživačkom pitanju. Prema Coelli i Perelman (1996) modeli orijentirani na output adekvatni su u slučaju da se istraživačko pitanje postavlja u obliku „koliko se može povećati output bez promjene razine inputa“. U ovom se radu polazi od pretpostavke da nositelji politika u gradovima imaju značajniji utjecaj na korištenje nekretnina nego na njihovu vrijednost. Konkretnije, nositelji politika u gradovima mogu utjecati na čimbenike koji određuju output (prihod) koji donose nekretnine, poput najmova, koncesija i sl.

Sljedeće, potrebno je pretpostaviti oblik prinosa na opseg, tj. donijeti odluku o pretpostavci konstantnih nasuprot varijabilnim prinosima na opseg. Cooper, Seiford i Tone (2005) ističu kako je pretpostavka konstantnih prinosa na opseg vrlo rigidna jer podrazumijeva da donositelji odluka djeluju u optimalnim uvjetima, poput savršene konkurencije, nesmetanog pristupa financiranju i sl. Međutim, u stvarnosti je takve uvjete gotovo nemoguće ostvariti pa se u primijenjenim analizama najčešće koristi pretpostavka varijabilnih prinosa na opseg (VRS).

Razlike između modela orijentiranih na input i modela orijentiranih na output, u ovisnosti o pretpostavci o obliku prinosa na opseg prikazane su na Slici 5.6. Slika pretpostavlja da se korištenjem jednog inputa x proizvodi jedan output y. Crna linija predstavlja proizvodnu funkciju. Na lijevom dijelu slike je prikazana funkcija proizvodnje koja ukazuje na varijabilne opadajuće prinose na opseg, što je standardna pretpostavka o obliku proizvodnih funkcija u ekonomiji. Na desnom dijelu slike je pretpostavljena funkcija proizvodnje s konstantnim prinosima. Točke B i D, koje se nalaze na proizvodnoj funkciji, predstavljaju točke učinkovite proizvodnje, dok točka P, koja se nalazi ispod proizvodne funkcije, predstavlja točku neučinkovite proizvodnje. Točka A prikazuje količinu outputa, a točka C količinu inputa koji se koristi za proizvodnju u točki P.

Ovisno o odabranoj orijentaciji modela tehnička učinkovitost u točki P može se definirati kao:

- model orijentiran na inpute TU = AB/AP (koliko se može smanjiti input da se dođe na granicu učinkovitosti, bez da se smanjuje output)
- model orijentiran na outpute TU = CP/CD (koliko se uz dani input može povećati output).

U oba je slučaja točka P neučinkovita (omjer manji od 1), ali se mjera tehničke učinkovitosti u slučaju varijabilnih prinosa između ova dva tipa modela razlikuje, dok je u slučaju konstantnih prinosa na opseg ona jednaka. Zato je u korištenju modela s varijabilnim prinosima na opseg važno odabrati adekvatnu orijentaciju modela.

Slika 5.6 DEA modeli i prinosi na opseg

(a) varijabilni prinosi na opseg (b) konstantni prinosi na opseg

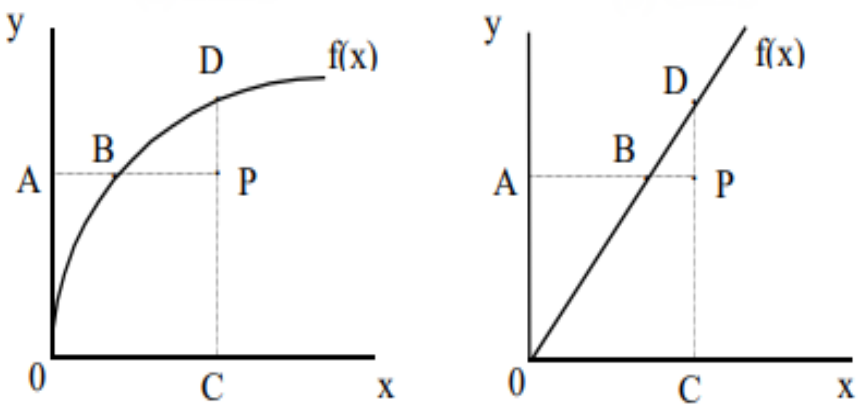

Izvor: Coelli (1996)

Zaključno, u ovoj se disertaciji koristi DEA model orijentiran na output s jednim inputom (vrijednost nekretnina po stanovniku) i jednim outputom (prihod od nekretnina po stanovniku), uz pretpostavku varijabilnih prinosa na opseg. Nakon što je definiran odgovarajući oblik DEA modela, u nastavku je objašnjen panel-Tobit model u kojem će se kao zavisna varijabla koristiti pokazatelj učinkovitosti upravljanja nekretninama definiran DEA modelom.

5.2.4. Definiranje Tobit panel modela

Kako bi se analizirale odrednice učinkovitosti upravljanja nekretninama u gradovima, predstavljeni DEA model u trećem koraku analize mora biti dopunjen analitičkim okvirom koji omogućava promatranje utjecaja pojedinih varijabli na pokazatelj učinkovitosti upravljanja nekretninama.

U ovoj se disertaciji za ispitivanje učinka ranije navedenih glavnih objašnjavajućih i kontrolnih varijabli na pokazatelj učinkovitosti upravljanja nekretninama koristi regresijska analiza, kao najčešće korištena metoda u empirijskim istraživanjima (Bahovec i sur., 2015), kojom se kvantificira odnos dviju ili više pojava. S obzirom na to da se analiza provodi među jedinicama promatranja (gradovima) u određenom razdoblju (2005. – 2016.), u radu se koristi panel regresijska analiza.

Odabir adekvatnog panel modela ovisi o nizu faktora, a u ovoj je disertaciji on određen prirodom zavisne varijable. Naime, u klasičnim linearnim regresijskim modelima zavisna varijabla je kontinuirana varijabla na čitavom skupu realnih brojeva. U ovoj disertaciji, međutim, zavisna varijabla, pokazatelj učinkovitosti upravljanja imovinom, ne može poprimiti bilo koju vrijednost, već je njezina vrijednost određena na intervalu:

$$\theta \in [0,1] \tag{5.3.}$$

Konkretno, radi se o latentnoj, neopazivoj varijabli koja poprima vrijednosti između 0 i 1.

Prema Mirdala (1983), u slučaju da je u model uključena latentna varijabla koja poprima samo određene vrijednosti, procjene dobivene metodom najmanjih kvadrata (eng. ordinary least squuare method) su pristrane, a procijenjeni parametri su i nekonzistentni.[19]

Zbog toga je u ovoj disertaciji nužno koristiti model ograničene zavisne varijable. Budući da zavisna varijabla poprima vrijednost nula ili pozitivne vrijednosti, ali ne negativne, pri čemu se radi o ograničenim vrijednostima zavisne varijable do jedan, u analizi odrednica pokazatelja učinkovitosti upravljanja nekretninama u hrvatskim gradovima odabrana je posebna vrsta modela ograničene zavisne varijable, tzv. Tobit model (Tobin, 1958). Tobit model koristi se u modelima u kojima zavisna varijabla poprima odrezane vrijednosti (eng. censored) pa se u literaturi ponekad naziva regresijski model s odrezanim vrijednostima (eng. censored regression model). Ovaj se model temelji na procjenama dobivenim metodom maksimalne vjerodostojnosti (eng. maximum likelihood).

[19] Poželjna svojstva procjenitelja u regresijskoj analizi su nepristranost, konzistentnost i efikasnost.

Opći oblik panel-Tobit modela sa zavisnom varijablom ograničenom na intervalu $[0,1]$ može se zapisati kao:

$$y_{it}^{*} = \beta X_{it} + \gamma Z_{it} + \varepsilon_{it} \tag{5.4.}$$

pri čemu je:

$$y^{*}{}_{it} = \begin{cases} 0\ ako\ y_{it}^{*} \leq 0 \\ 1\ ako\ y_{it}^{*} \geq 1 \\ y_{it}^{*}\ ako\ 0 < \theta_{it}^{*} < 1 \end{cases}$$

gdje y_{it}^{*} predstavlja zavisnu varijablu s odrezanim vrijednostima između 0 i 1, X_{it} sadrži skup glavnih objašnjavajućih varijabli, β je vektor parametara uz glavne objašnjavajuće varijable, Z_{it} sadrži skup kontrolnih varijabli, γ je vektor parametara uz kontrolne varijable, a ε_{it} je greška relacije. i predstavljaju jedinice promatranja, a t vremenska razdoblja.

U ovoj je disertaciji zavisna varijabla pokazatelj učinkovitosti, čije se vrijednosti mogu definirati kao:

$$pokazatelj\ učinkovitosti\ \theta_{i,t} = \begin{cases} 0\ za\ potpuno\ neučinkovito\ upravljanje\ nekretninama \\ između\ 0\ i\ 1\ za\ relativno\ učinkovito\ upravljanje\ nekretninama \\ 1\ za\ potpuno\ učinkovito\ upravljanje\ nekretninama \end{cases}$$

Prema tome, panel-Tobit model korišten u ovoj disertaciji može se zapisati kao:

$$\theta_{it}^{*} = \beta X_{it} + \gamma Z_{it} + \varepsilon_{it} \tag{5.5.}$$

pri čemu je

$$\theta^{*}{}_{it} = \begin{cases} 0\ ako\ \theta_{it}^{*} \leq 0 \\ 1\ ako\ \theta_{it}^{*} \geq 1 \\ \theta_{it}^{*}\ ako\ 0 < \theta_{it}^{*} < 1 \end{cases}$$

Skupovi glavnih objašnjavajućih i kontrolnih varijabli definirani su kao:

$$X_{it} = \begin{bmatrix} lokacija_{i,t} \\ {}^{20}sjedište\ županije_{i,t} \\ primjena\ PRLS_{i,t} \end{bmatrix} \quad Z_{it} = \begin{bmatrix} nezaposlenost\ stanovništva_{i,t} \\ poduzetnička\ aktivnost_{i,t} \\ fiskalni\ kapacitet_{i,t} \end{bmatrix}$$

U istraživanju su procijenjena tri zasebna Tobit modela za svaku skupinu gradova pa je vremenska dimenzija uzroka ista za sve skupine gradova, dok se prostorna dimenzija razlikuje. Prostorna i vremenska dimenzija analize definirane su kako slijedi.

Za skupinu malih gradova:

[20] Samo za skupinu velikih gradova.

$$i = 1, \dots, 58$$

$$t = 2005, \dots, 2016$$

Za skupinu srednje velikih gradova:

$$i = 1, \dots, 43$$

$$t = 2005, \dots, 2016$$

Za skupinu velikih gradova:

$$i = 1, \dots, 25$$

$$t = 2005, \dots, 2016$$

Nakon definiranja odgovarajućeg oblika panel regresijskog modela u nastavku rada su prikazani temeljni rezultati istraživanja.

5.3. Rezultati empirijskog istraživanja

U ovom se dijelu rada prikazuju rezultati empirijskog istraživanja, pri čemu prikaz rezultata slijedi redoslijed postavljenih hipoteza. Prvo će se prikazati izračunati pokazatelji učinkovitosti upravljanja nekretninama iz DEA modela prema skupinama gradova kako bi se utvrdilo koliko učinkovito gradovi u Hrvatskoj upravljaju nekretninama. Nakon toga će se analizirati razlike u učinkovitosti upravljanja nekretninama između velikih gradova i ostalih skupina gradova kako bi se utvrdilo upravljaju li veliki gradovi učinkovitije nekretninama u svojem vlasništvu. Sljedeće, analiziraju se rezultati na temelju kojih će se utvrditi upravljaju li primorski gradovi učinkovitije nekretninama u svojem vlasništvu od ostalih gradova. Zatim se prikazuju rezultati na temelju kojih će se utvrditi upravljaju li gradovi koji su sjedišta županija učinkovitije nekretninama u svojem vlasništvu od ostalih velikih gradova. Konačno, u zadnjem se dijelu prikazuju rezultati kojima se utvrđuje upravljaju li gradovi koji su implementirali PRLS model učinkovitije nekretninama u svojem vlasništvu od ostalih gradova.

5.3.1. Učinkovitost upravljanja nekretninama u hrvatskim gradovima

Prvi dio rezultata odnosi se na učinkovitost upravljanja nekretninama u hrvatskim gradovima, pri čemu se rezultati interpretiraju u kontekstu ***prve hipoteze kojom se pretpostavlja kako hrvatski gradovi ne upravljaju učinkovito nekretninama u svojem vlasništvu***.

Navedena se hipoteza testira DEA modelom, tj. očitovanje o hipotezi temelji se na rezultatima DEA modela, odnosno na vrijednosti izračunatog pokazatelja učinkovitosti upravljanja nekretninama u gradovima, koji se označava s θ.

U literaturi je utvrđeno da se jedinice odlučivanja, u ovom slučaju gradovi, koje imaju pokazatelj učinkovitosti $\theta > 0{,}9$ (npr. Barra i Zoti, 2014) mogu smatrati učinkovitim pa će se taj kriterij koristiti i u ovom istraživanju. Gradovi koji imaju vrijednost parametra $\theta < 0{,}9$ smatraju se neučinkovitim. Hipoteza će biti prihvaćena ako u svakoj skupi gradova (po veličini) više od 70% gradova iz svake pojedine skupine ne upravlja učinkovito, odnosno pokazatelj učinkovitosti $\theta > 0{,}9$.

Tablica 5.10. prikazuje prosječnu vrijednost pokazatelja učinkovitosti u skupini malih gradova. Podaci pokazuju kako je granica učinkovitosti u ovoj skupini gradova određena položajem Klanjca, Novalje, Novigrada, Obrovca i Vodnjana, dok se blizu granice (pokazatelj učinkovitosti iznad 0,9) nalaze još Skradin i Otok. Dakle, ukupno sedam gradova zadovoljava kriterij učinkovitosti, što znači da u skupini malih gradova samo 12% gradova učinkovito upravlja nekretninama u svojem vlasništvu.

Gradovi s najnižom prosječnom vrijednošću pokazatelja učinkovitosti upravljanja nekretninama (ispod 0,05) su Zlatar, Vodice, Glina, Komiža, Donja Stubica, Vrgorac, Čabar i Varaždinske Toplice.

Tablica 5-10 Pokazatelj učinkovitosti upravljanja nekretninama – mali gradovi

Redni broj	Ime grada	θ	Redni broj	Ime grada	θ	Redni broj	Ime grada	θ
1	Klanjec	1.00	**21**	Čazma	0.37	**41**	Mursko Središće	0.115
2	Novalja	1.00	**22**	Korčula	0.36	**42**	Delnice	0.113
3	Novigrad-Cittanova	1.00	**23**	Hvar	0.30	**43**	Ozalj	0.112
4	Obrovac	1.00	**24**	Lipik	0.29	**44**	Ludbreg	0.102
5	Vodnjan	1.00	**25**	Slunj	0.27	**45**	Vrbovsko	0.102
6	Skradin	0.97	**26**	Opuzen	0.26	**46**	Pregrada	0.089
7	Otok	0.97	**27**	Nin	0.25	**47**	Đurđevac	0.089
8	Biograd na Moru	0.82	**28**	Ilok	0.24	**48**	Stari Grad	0.087
9	Mali Lošinj	0.72	**29**	Hrvatska Kostajnica	0.22	**49**	Pakrac	0.065
10	Buje	0.71	**30**	Grubišno Polje	0.21	**50**	Lepoglava	0.057
11	Cres	0.65	**31**	Buzet	0.19	**51**	Varaždinske Toplice	0.048
12	Pag	0.64	**32**	Orahovica	0.19	**52**	Čabar	0.047
13	Trilj	0.64	**33**	Donji Miholjac	0.18	**53**	Vrgorac	0.047
14	Supetar	0.59	**34**	Kraljevica	0.17	**54**	Donja Stubica	0.047
15	Krk	0.48	**35**	Zabok	0.17	**55**	Komiža	0.046
16	Vis	0.47	**36**	Drniš	0.17	**56**	Glina	0.041
17	Senj	0.46	**37**	Otočac	0.16	**57**	Vodice	0.032
18	Novi Vinodolski	0.44	**38**	Rab	0.16	**58**	Zlatar	0.030
19	Prelog	0.42	**39**	Oroslavje	0.16			
20	Bakar	0.38	**40**	Vrlika	0.15			

Izvor: izračun autora

Tablica 5.11. prikazuje prosječnu vrijednost pokazatelja učinkovitosti u skupini srednje velikih gradova. Podaci pokazuju kako je granica učinkovitosti u ovoj skupini gradova određena položajem Benkovca, Omiša, Opatije i Poreča, dok se nijedan drugi grad ne nalazi blizu granice učinkovitosti, s vrijednošću pokazatelja učinkovitosti iznad 0,9. U ovom slučaju, ukupno četiri grada zadovoljava kriterij učinkovitosti, što znači da u skupini srednje velikih gradova samo 9% gradova učinkovito upravlja nekretninama u svojem vlasništvu.

Gradovi s najnižom prosječnom vrijednošću pokazatelja učinkovitosti upravljanja nekretninama (ispod 0,05) su Sveti Ivan Zelina, Sveta Nedjelja i Petrinja.

Tablica 5-11 Pokazatelj učinkovitosti upravljanja nekretninama – srednje veliki gradovi

Redni broj	Ime grada	θ	Redni broj	Ime grada	θ	Redni broj	Ime grada	θ
1	Benkovac	1.00	**21**	Solin	0.24	**41**	Sveti Ivan Zelina	0.044
2	Omiš	1.00	**22**	Knin	0.22	**42**	Sveta Nedelja	0.019
3	Opatija	1.00	**23**	Našice	0.20	**43**	Petrinja	0.018
4	Poreč	1.00	**24**	Ivanić-Grad	0.20			
5	Trogir	0.89	**25**	Duga Resa	0.20			
6	Rovinj	0.62	**26**	Nova Gradiška	0.19			
7	Umag	0.57	**27**	Sinj	0.19			
8	Ploče	0.46	**28**	Kutina	0.17			
9	Labin	0.44	**29**	Kastav	0.16			
10	Beli Manastir	0.39	**30**	Jastrebarsko	0.13			
11	Slatina	0.36	**31**	Novska	0.11			
12	Crikvenica	0.35	**32**	Vrbovec	0.10			
13	Županja	0.35	**33**	Križevci	0.10			
14	Zaprešić	0.34	**34**	Pleternica	0.08			
15	Dugo Selo	0.32	**35**	Ivanec	0.07			
16	Belišće	0.31	**36**	Đakovo	0.07			
17	Daruvar	0.28	**37**	Imotski	0.06			
18	Valpovo	0.26	**38**	Ogulin	0.06			
19	Makarska	0.25	**39**	Metković	0.05			
20	Garešnica	0.25	**40**	Novi Marof	0.05			

Izvor: izračun autora

Konačno, Tablica 5.12. prikazuje prosječnu vrijednost pokazatelja učinkovitosti u skupini velikih gradova. Podaci pokazuju kako je granica učinkovitosti u ovoj skupini gradova određena položajem Pazina, Rijeke i Velike Gorice, dok se Varaždin, Zadar i Pula nalaze blizu granice učinkovitosti, s vrijednošću pokazatelja učinkovitosti iznad 0,9. U ovom slučaju, ukupno šest gradova zadovoljava kriterij učinkovitosti, što znači da u skupini velikih gradova 24% gradova učinkovito upravlja nekretninama u svojem vlasništvu. Iako su rezultati za skupinu velikih gradova nešto povoljniji u odnosu na ostale skupine, podaci pokazuju da manje od četvrtine velikih gradova učinkovito upravlja nekretninama u svojem vlasništvu.

U skupini velikih gradova nema gradova s vrlo niskim pokazateljem učinkovitosti upravljanja nekretninama, a najniže vrijednosti ostvaruju Požega (0,18) i Gospić (0,16).

Tablica 5-12 Pokazatelj učinkovitosti upravljanja nekretninama – veliki gradovi

Redni broj	Ime grada	θ	Redni broj	Ime grada	θ
1	Pazin	1.00	**21**	Vinkovci	0.30
2	Rijeka	1.00	**22**	Slavonski Brod	0.28
3	Velika Gorica	1.00	**23**	Bjelovar	0.27
4	Pula	0.94	**24**	Požega	0.18
5	Zadar	0.92	**25**	Gospić	0.16
6	Varaždin	0.90			
7	Dubrovnik	0.82			
8	Virovitica	0.75			
9	Čakovec	0.66			
10	Koprivnica	0.65			
11	Zagreb	0.65			
12	Vukovar	0.62			
13	Karlovac	0.62			
14	Samobor	0.57			
15	Kaštela	0.55			
16	Sisak	0.51			
17	Split	0.46			
18	Osijek	0.44			
19	Krapina	0.43			
20	Šibenik	0.32			

Izvor: izračun autora

Rezultati ovog dijela analize pokazuju kako je učinkovitost upravljanja nekretninama u vlasništvu gradova na niskoj razini u svim skupinama gradova. U skupini malih gradova samo 12% gradova učinkovito upravlja nekretninama u svojem vlasništvu, u skupini srednje velikih 9%, a u skupini velikih 24%. Promatrajući svaku od skupina pojedinačno i sve analizirane gradove zajedno, može se zaključiti kako više od 70% gradova ne upravlja učinkovito.

Na temelju prikazanih rezultata može se potvrditi hipoteza H1 da gradovi u Republici Hrvatskoj ne upravljaju učinkovito nekretninama u svojem vlasništvu.

5.3.2. Učinkovitost upravljanja nekretninama u velikim gradovima u usporedbi s ostalim gradovima

Nakon što je analizirana učinkovitost hrvatskih gradova u upravljaju nekretninama u svojem vlasništvu, za sve skupine gradova u ovom dijelu rada ispituje se upravljaju li veliki gradovi svojim nekretninama učinkovitije od malih i srednjih. Kako je ranije navedeno, veliki je grad jedinica lokalne samouprave koja je ujedno gospodarsko, financijsko, kulturno, zdravstveno, prometno i znanstveno središte razvitka šireg okruženja i koja ima više od 35.000 stanovnika. Srednji grad je onaj s brojem stanovnika između 10.000 i 35.000, te mali grad s brojem stanovnika manjim od 10.000.

Veliki gradovi zakonom imaju definirano širi popis obaveza i usluga koje moraju pružati privatnim i pravnim osobama sa svojeg područja. Slijedom navedenog, imaju potrebu ustrojiti organizacijske jedinice te ih kadrovski ekipirati kako bi mogli izvršavati sve zakonom definirane obaveze i dužnosti. Veći broj zaposlenika gradske uprave s određenim stručnim znanjima i iskustvom koji su zaposleni u resornim upravnim odjelima i/ili odsjecima mogu doprinijeti kvalitetnijem upravljanju nekretninama koje su u vlasništvu grada.

U prethodno prikazanim rezultatima već je pokazano da je postotak gradova koji se nalaze na granici učinkovitosti u skupini velikih gradova (24%) značajno veći u odnosu na skupinu srednjih (9%) i malih (12%) gradova. Također je pokazano kako u skupini velikih gradova ne postoje gradovi s ekstremno niskim pokazateljem učinkovitosti upravljanja nekretninama. Ovi ***rezultati idu u prilog hipotezi H2 prema kojoj veliki gradovi učinkovitije upravljaju nekretninama u svojem vlasništvu.*** Međutim, kako bi odnos pokazatelja učinkovitosti

upravljanja nekretninama među ovim skupinama gradova preciznije utvrdio, potrebno je analizirati njihova glavna statistička obilježja.

Očitovanje o hipotezi H2 temelji se na rezultatima analize omeđivanja podataka pri čemu se analizira veličina pokazatelja učinkovitosti upravljanja nekretninama u svakoj skupini gradova na način da se uspoređuju medijani pokazatelja θ između skupina gradova po njihovoj veličini. U tu se svrhu koristi B-P dijagram (eng. box plot) koji se temelji na pet osnovnih pokazatelja: najmanjoj vrijednosti, najvećoj vrijednosti, medijanu, prvom kvartilu i trećem kvartilu. Također, B-P dijagram prikazuje i interval pouzdanosti procjene medijana.

B-P dijagrami za sve skupine gradova prikazani su na Slici 5.7. Medijan je prikazan crnom linijom, aritmetička sredina prikazana je crnom točkom, interval pouzdanosti predstavljen je osjenčanim područjem, a plavi pravokutnik određuje prvi i treći kvartil. Podaci o minimumu i maksimumu nisu prikazani zbog bolje preglednosti rezultata.

Slika 5.7 B-P dijagram – ukupna učinkovitost

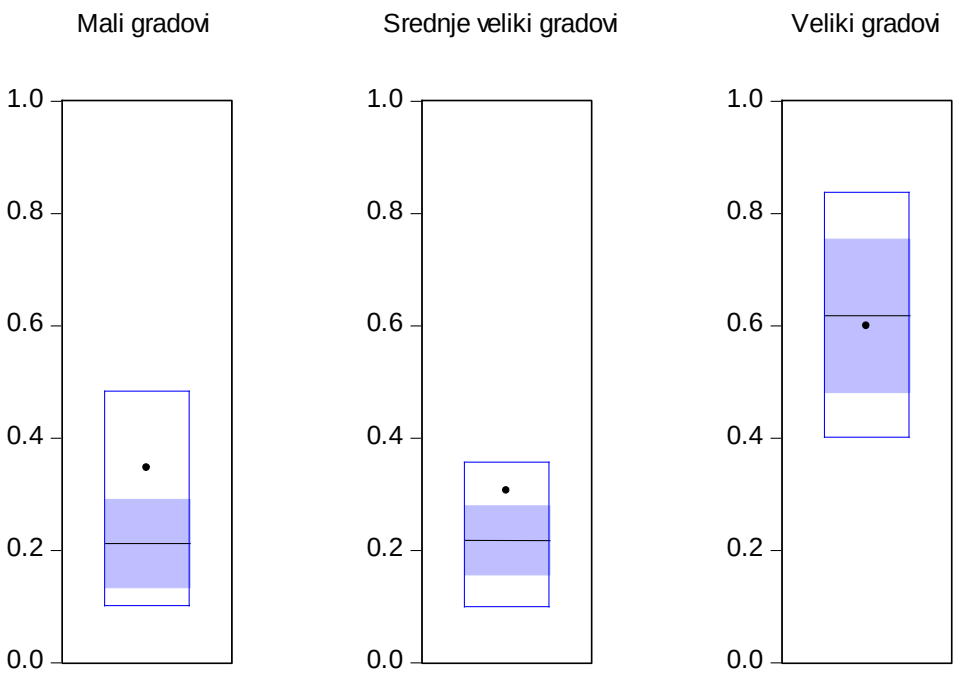

Izvor: izračun autora

Slika pokazuje kako je medijan pokazatelja učinkovitosti upravljanja nekretninama u velikim gradovima značajno veći u odnosu na male i srednje gradove. Medijan u skupini malih gradova iznosi 0,21, u skupini srednje velikih gradova 0,23, a u skupini velikih gradova 0,62. Robusnost ovakvog zaključka potvrđena je i činjenicom da je donji interval pouzdanosti procijenjenog

medijana u skupini velikih gradova značajno veći od gornjih intervala pouzdanosti procijenjenih medijana u skupini malih i srednje velikih gradova.

Dakle, u skupini velikih gradova postotak gradova koji učinkovito upravljaju nekretninama u svojem vlasništvu značajno je veći u odnosu na male i srednje gradove, najniže vrijednosti pokazatelja učinkovitosti u skupini velikih gradova značajno su veće od najnižih vrijednosti pokazatelja učinkovitosti u skupinama malih i srednjih gradova, dok je medijan pokazatelja učinkovitosti u skupini velikih gradova značajno veći od medijana pokazatelja učinkovitosti u skupinama malih i srednjih gradova.

Na temelju navedenih rezultata može se potvrditi hipoteza H2 da veliki gradovi učinkovitije upravljaju nekretninama u svojem vlasništvu od ostalih skupina gradova.

5.3.3. Učinkovitost upravljanja nekretninama s obzirom na geografski položaj gradova

Osim veličine grada, u ovoj se disertaciji istražuje i učinak geografskog položaja grada na pokazatelj učinkovitosti upravljanja nekretninama u gradovima.

Promatrajući zemljopisni položaj Republike Hrvatske, u ovom dijelu rada nastoji se dokazati hipoteza da primorski gradovi učinkovitije upravljaju i raspolažu s nekretninama u svome vlasništvu ostalih gradova. Primorski gradovi su oni koji se svojim rubnim granicama područja nalaze i/ili dodiruju morsku obalu. Gradovi koji lokacijom zadovoljavaju uvjet da su smješteni uz morsku obalu svojim položajem predstavljaju veći turistički potencijal u odnosu na gradove koji nisu smješteni uz more. Veća vrijednost nekretnina kao i potražnja za njima upravo na ovakvim lokacijama dolazi do izražaja i omogućuje vlasnicima bolje prinose. Sukladno tome gradovi koji su smješteni uz more uložit će veće resurse u svoje vlastite nekretnine kako bi maksimalno iskoristili njihov potencijal.

Stoga se u ovom radu hipotezom ***H3 pretpostavlja da gradovi koji su smješteni uz more učinkovitije upravljaju nekretninama u svojem vlasništvu od gradova u unutrašnjosti*.**

Očitovanje o toj hipotezi temelji se na: (i) usporedbi medijana pokazatelja učinkovitosti upravljanja nekretninama dobivenim metodom omeđivanja podataka između skupina gradova (primorski nasuprot ostalim gradovima u svakoj skupini gradova prema veličini) i (ii) na

temelju rezultata Tobit panel analize uključivanjem binarne varijable „lokacija“ u analizu, pri čemu ona poprima vrijednost 1 za primorske gradove i 0 za ostale gradove.

- ***Mali gradovi***

Na Slici 5.8. prikazani su B-P dijagrami koji omogućavaju usporedbu medijana pokazatelja učinkovitosti upravljanja nekretninama (crna linija) između malih gradova uz obalu i ostalih malih gradova. Prosječan medijan pokazatelja učinkovitosti upravljanja nekretninama malih gradova uz obalu u promatranom je razdoblju iznosio 0,46, dok je za ostale male gradove iznosio 0,16. Robusnost ovakvog zaključka potvrđena je i činjenicom da je donja granica intervala pouzdanosti procijenjenog medijana u skupini malih gradova uz obalu značajno viša od gornje granice intervala pouzdanosti procijenjenih medijana u skupini ostalih gradova.

Slika 5.8 B-P dijagram – usporedba malih gradova na obali i ostalih gradova

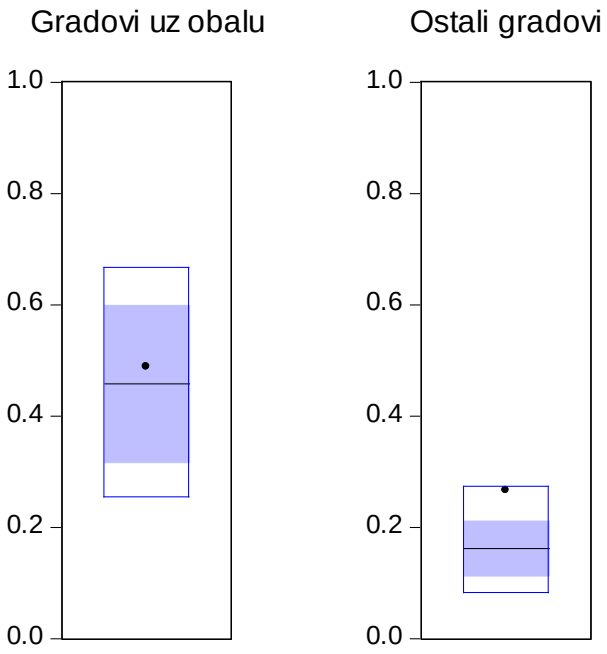

Izvor: izračun autora

Treća se hipoteza dodatno testira i prethodno objašnjenim panel-Tobit modelom, koji kao glavnu objašnjavajuću varijablu uključuje binarnu varijablu *lokacija*, koja poprima vrijednost 1 u slučaju da se grad nalazi uz obalu i 0 u slučaju da se ne nalazi uz obalu, uz odgovarajuće kontrolne varijable, fiskalni kapacitet gradova, poduzetničku aktivnost u gradovima te pokazatelj nezaposlenosti.

Rezultati panel-Tobit modela za skupinu malih gradova prikazani su u Tablici 5.13. Rezultati pokazuju kako je procijenjeni koeficijent uz varijablu lokacija pozitivan, što je u skladu s očekivanjem. Međutim, p-vrijednost ukazuje kako učinak ove varijable na pokazatelj učinkovitosti upravljanja nekretninama nije statistički signifikantan. Kontrolne varijable fiskalni kapacitet i poduzetnička aktivnost imaju statistički značajan učinak na pokazatelj učinkovitosti upravljanja nekretninama, s očekivanim predznakom, dok učinak pokazatelja nezaposlenosti nije statistički signifikantan.

Tablica 5-13 Rezultati panel-Tobit modela za skupinu malih gradova

Dependent Variable: EF
Method: ML - Censored Normal (TOBIT) (Newton-Raphson / Marquardt steps)
Sample: 2005 2016
Included observations: 696
Left censoring (value) series: 0
Right censoring (value) series: 1
Convergence achieved after 5 iterations
Coefficient covariance computed using observed Hessian

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.161035	0.044945	3.582926	0.0003
LOKACIJA	**0.005678**	**0.028314**	**0.200538**	**0.8411**
FISKALNI KAPACITET	0.013731	0.006719	2.043705	0.0410
PODUZ. AKTIVNOST	0.043863	0.013757	3.188334	0.0014
NEZAPOSLENOST	0.042147	0.417301	0.101000	0.9196
Error Distribution				
SCALE:C(6)	0.282397	0.008051	35.07816	0.0000

Mean dependent var	0.275156	S.D. dependent var	0.271240
S.E. of regression	0.267028	Akaike info criterion	0.516364
Sum squared resid	49.19976	Schwarz criterion	0.555548
Log likelihood	-173.6946	Hannan-Quinn criter.	0.531515
Avg. log likelihood	-0.249561		

Left censored obs	0	Right censored obs	48
Uncensored obs	648	Total obs	696

Izvor: izračun autora; ispis EViews 9

- ***Srednje veliki gradovi***

Na Slici 5.9. prikazani su B-P dijagrami koji omogućavaju usporedbu medijana pokazatelja učinkovitosti upravljanja nekretninama (crna linija) između srednje velikih gradova uz obalu i

ostalih srednje velikih gradova. Prosječan medijan pokazatelja učinkovitosti upravljanja nekretninama srednje velikih gradova uz obalu u promatranom je razdoblju iznosio 0,60, dok je za ostale gradove iznosio 0,19. Robusnost ovakvog zaključka potvrđena je i činjenicom da je donja granica intervala pouzdanosti procijenjenog medijana u skupini srednje velikih gradova uz obalu značajno viša od gornje granice intervala pouzdanosti procijenjenih medijana u skupini ostalih gradova.

Slika 5.9 B-P dijagram – usporedba srednje velikih gradova na obali i ostalih gradova

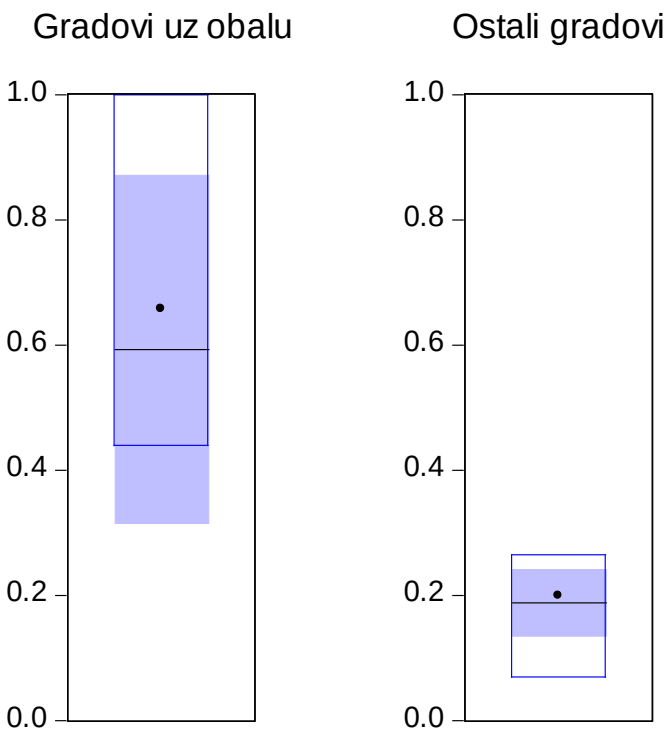

Izvor: izračun autora

Treća se hipoteza i u ovom slučaju dodatno testira i prethodno objašnjenim panel-Tobit modelom, koji kao glavnu objašnjavajuću varijablu uključuje binarnu varijablu *lokacija*, koja poprima vrijednost 1 u slučaju da se grad nalazi uz obalu i 0 u slučaju da se ne nalazi uz obalu, uz odgovarajuće kontrolne varijable, fiskalni kapacitet gradova, poduzetničku aktivnost u gradovima te pokazatelj nezaposlenosti.

Rezultati panel-Tobit modela za skupinu srednje velikih gradova prikazani su u Tablici 5.14. Rezultati pokazuju kako je procijenjeni koeficijent uz varijablu lokacija pozitivan, što je u skladu s očekivanjem. P-vrijednost ukazuje kako je učinak ove varijable na pokazatelj učinkovitosti upravljanja nekretninama statistički signifikantan. Kontrolne varijable u ovom

modelu nemaju statistički značajan učinak na pokazatelj učinkovitosti upravljanja nekretninama.

Tablica 5-14 Rezultati panel-Tobit modela za skupinu srednje velikih gradova

Dependent Variable: EF
Method: ML - Censored Normal (TOBIT) (Newton-Raphson / Marquardt steps)
Sample: 2005 2016
Included observations: 516
Left censoring (value) series: 0
Right censoring (value) series: 1
Convergence achieved after 5 iterations
Coefficient covariance computed using observed Hessian

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.190804	0.051594	3.698198	0.0002
LOKACIJA	**0.248771**	**0.041703**	**5.965340**	**0.0000**
FISKALNI KAPACITET	0.000104	0.013258	-0.007826	0.9938
PODUZ. AKTIVNOST	0.017694	0.020713	-0.854251	0.3930
NEZAPOSLENOST	0.228731	0.419940	0.544676	0.5860
Error Distribution				
SCALE:C(6)	0.281588	0.009422	29.88710	0.0000

Mean dependent var	0.230527	S.D. dependent var	0.273674
S.E. of regression	0.265568	Akaike info criterion	0.545858
Sum squared resid	35.96857	Schwarz criterion	0.595232
Log likelihood	-134.8314	Hannan-Quinn criter.	0.565206
Avg. log likelihood	-0.261301		

Left censored obs	0	Right censored obs	41
Uncensored obs	475	Total obs	516

Izvor: izračun autora; ispis EViews 9

- **Veliki gradovi**

Na Slici 5.10. prikazani su B-P dijagrami koji omogućavaju usporedbu medijana pokazatelja učinkovitosti upravljanja nekretninama (crna linija) između velikih gradova uz obalu i ostalih velikih gradova. Prosječan medijan pokazatelja učinkovitosti upravljanja nekretninama velikih gradova uz obalu u promatranom je razdoblju iznosio 0,81, dok je za ostale gradove iznosio 0,59. Međutim, ovaj zaključak treba tumačiti s dozom opreza budući da je donja granica intervala pouzdanosti procijenjenog medijana u skupini velikih gradova uz obalu manja od gornje granice intervala pouzdanosti i samog medijana u skupini ostalih gradova.

Slika 5.10 B-P dijagram – usporedba velikih gradova na obali i ostalih gradova

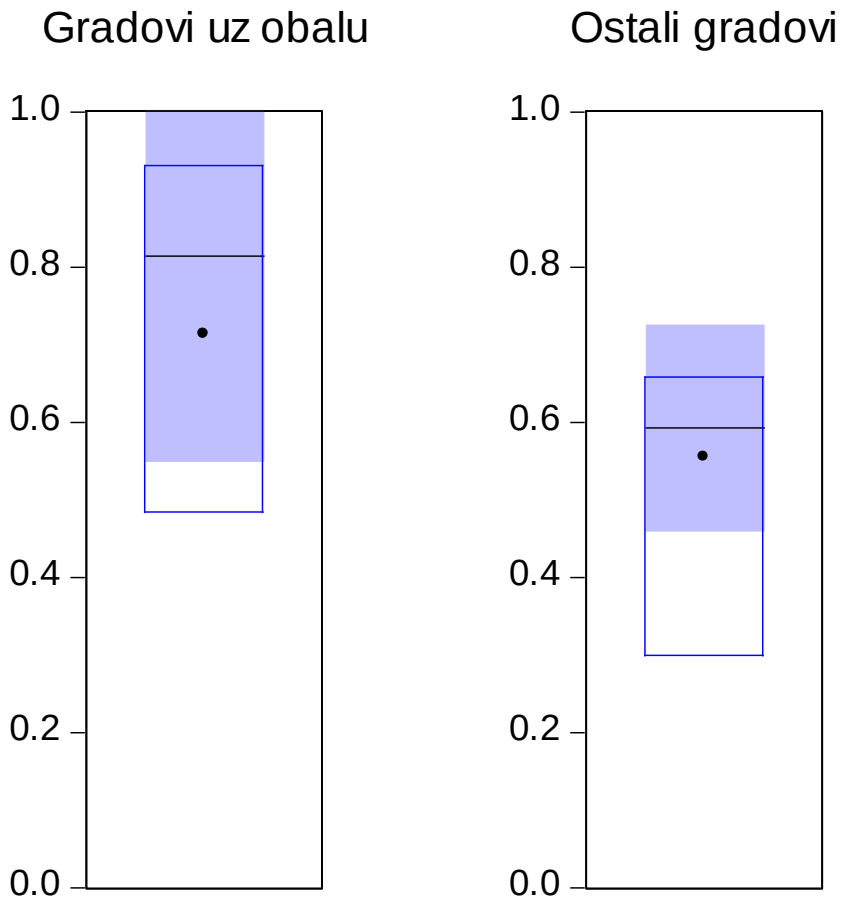

Izvor: izračun autora

Konačno, treća hipoteza se dodatno testira i prethodno objašnjenim panel-Tobit modelom, koji kao glavnu objašnjavajuću varijablu uključuje binarnu varijablu *lokacija*, koja poprima vrijednost 1 u slučaju da se grad nalazi uz obalu i 0 u slučaju da se ne nalazi uz obalu, uz odgovarajuće kontrolne varijable, fiskalni kapacitet gradova, poduzetničku aktivnost u gradovima te pokazatelj nezaposlenosti.

Rezultati panel-Tobit modela za skupinu velikih gradova prikazani su u Tablici 5.15. Rezultati pokazuju kako je procijenjeni koeficijent uz varijablu lokacija pozitivan, što je u skladu s očekivanjem. Međutim, p-vrijednost ukazuje kako učinak ove varijable na pokazatelj učinkovitosti upravljanja nekretninama nije statistički signifikantan. Kontrolne varijable fiskalni kapacitet i poduzetnička aktivnost imaju statistički značajan učinak na pokazatelj učinkovitosti upravljanja nekretninama, s očekivanim predznakom, dok učinak pokazatelja nezaposlenosti nije statistički signifikantan.

Tablica 5-15 Rezultati panel-Tobit modela za skupinu velikih gradova

Dependent Variable: EF

Method: ML - Censored Normal (TOBIT) (Newton-Raphson / Marquardt steps)

Sample: 2005 2016

Included observations: 1512

Left censoring (value) series: 0

Right censoring (value) series: 1

Convergence achieved after 5 iterations

Coefficient covariance computed using observed Hessian

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.213978	0.035325	6.057340	0.0000
LOKACIJA	0.015469	0.021848	0.708026	0.4789
FISKALNI KAPACITET	0.020696	0.005953	3.476461	0.0005
PODUZ. AKTIVNOST	0.002935	0.001093	2.685722	0.0072
NEZAPOSLENOST	-0.327812	0.307162	-1.067228	0.2859
Error Distribution				
SCALE:C(6)	0.313588	0.006182	50.72214	0.0000

Mean dependent var	0.299019	S.D. dependent var	0.293627
S.E. of regression	0.290031	Akaike info criterion	0.740188
Sum squared resid	126.6818	Schwarz criterion	0.761304
Log likelihood	-553.5824	Hannan-Quinn criter.	0.748052
Avg. log likelihood	-0.366126		

Left censored obs	0	Right censored obs	138
Uncensored obs	1374	Total obs	1512

Izvor: izračun autora; ispis EViews 9

Dakle, rezultati prikazani u ovom dijelu rada upućuju na to da se **hipoteza da gradovi smješteni uz more učinkovitije upravljaju nekretninama u svojem vlasništvu (H3) može**

djelomično potvrditi. Pristup usporedbe medijana pokazuje kako je medijan pokazatelja učinkovitosti upravljanja gradovima u svim skupinama primorskih gradova veći od medijana pokazatelja učinkovitosti upravljanja gradovima u ostalim gradovima, dok pristup panel-Tobit analize ovaj zaključak dodatno potvrđuje samo za skupinu srednje velikih gradova. U ostalim skupinama gradova utjecaj lokacije ima očekivano pozitivan predznak na pokazatelj učinkovitosti upravljanja gradovima, ali on nije statistički signifikantan.

5.3.4. Učinkovitost upravljanja nekretninama u gradovima županijskim središtima u usporedbi s ostalim gradovima

Gradovi županijska sjedišta su jedinice lokalne samouprave koje zbog svoj položaja i normativnog uređenja predstavljaju središta svojeg regionalnog područja čime takvim položajem jačaju društveni utjecaj i gospodarske aktivnosti u svom geografskom području.

U gradovima koji su sjedišta županija moguće je konzumirati usluge određenih funkcija središnje države koje su prenesene na županijska središta. Sukladno navedenom, u županijskim središtima nalaze se relevantne institucije, a samim time i nekretnine su u funkciji upravljanja županijama. Ti su gradovi često i kulturna središta županija, čime se dodatno povećava iskorištenost nekretnina (kazališta, kina, muzeji, udruge i sl.). Navedeni gradovi često su i sjedišta poduzeća, a i većina svakodnevnog poslovanja koncentrirana je u njima, čime se povećava i broj gradskih i drugih prostora koji se koriste u poslovne svrhe.
Zato se u ovom radu iznosi hipoteza ***H4 koja pretpostavlja da gradovi koji su sjedišta županija bolje upravljanju nekretninama u svojem vlasništvu od ostalih gradova.***

Očitovanje o ovoj hipotezi temelji se na: (i) usporedbi medijana pokazatelja učinkovitosti upravljanja nekretninama dobivenim metodom omeđivanja podataka između skupina gradova (sjedišta županija nasuprot ostalim gradovima) i (ii) rezultatima panel-Tobit analize uključivanjem binarne varijable „sjedišta“ u analizu, pri čemu ona poprima vrijednost 1 za gradove sjedišta županija i 0 za ostale gradove.

Na Slici 5.11. prikazani su B-P dijagrami koji omogućavaju usporedbu medijana pokazatelja učinkovitosti upravljanja nekretninama (crna linija) između gradova koji su županijska središta i ostalih gradova.

Slika 5.11 B-P dijagram – usporedba velikih gradova koji su sjedišta županija i ostalih gradova

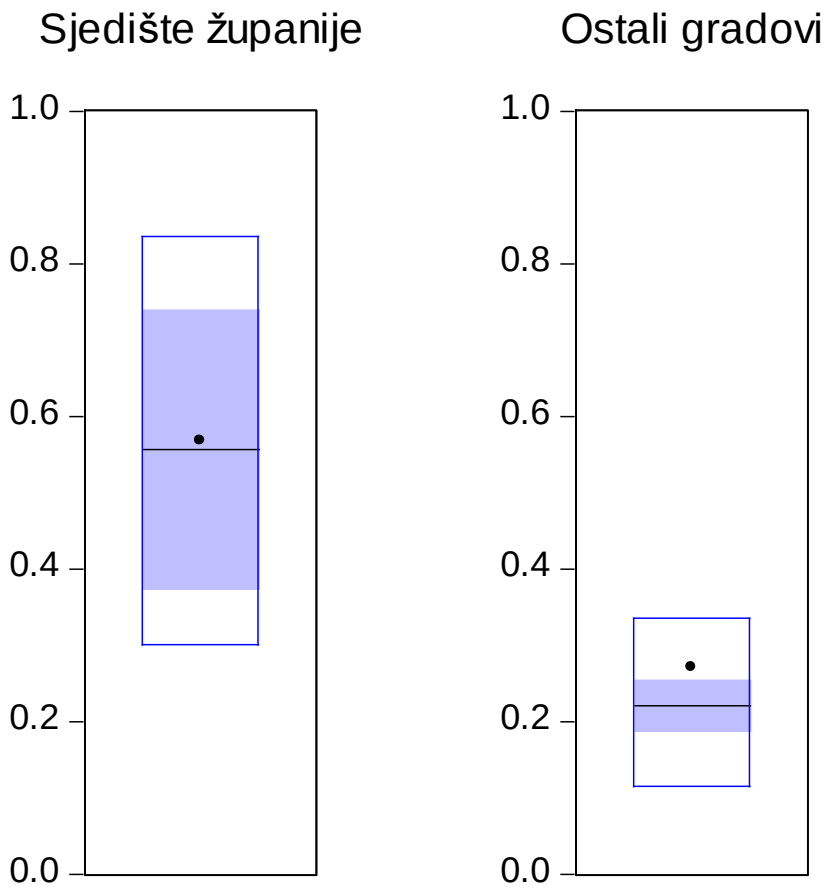

Izvor: izračun autora

Prosječan medijan pokazatelja učinkovitosti upravljanja nekretninama gradova koji su županijska središta u promatranom je razdoblju iznosio 0,55, dok je za ostale gradove iznosio 0,22. Robusnost ovakvog zaključka potvrđena je i činjenicom da je donja granica intervala pouzdanosti procijenjenog medijana u skupini gradova koji su županijska središta značajno veća od gornje granice intervala pouzdanosti procijenjenih medijana u skupini ostalih gradova.

Četvrta hipoteza dodatno se testira i prethodno objašnjenim panel-Tobit modelom, koji kao glavnu objašnjavajuću varijablu uključuje binarnu varijablu *sjedište županije*, koja poprima vrijednost 1 u slučaju da je grad sjedište županije i 0 u slučaju da nije, uz odgovarajuće kontrolne varijable, fiskalni kapacitet gradova, poduzetničku aktivnost u gradovima te pokazatelj nezaposlenosti. Rezultati panel-Tobit modela prikazani su u Tablici 5.16.

Tablica 5-16 Rezultati panel-Tobit modela na uzorku svih gradova – županijskih sjedišta

Dependent Variable: EF
Method: ML - Censored Normal (TOBIT) (Newton-Raphson / Marquardt steps)
Sample: 2005 2016
Included observations: 1512
Left censoring (value) series: 0
Right censoring (value) series: 1
Convergence achieved after 5 iterations
Coefficient covariance computed using observed Hessian

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.182428	0.034559	5.278711	0.0000
SJEDIŠTE	**0.183810**	**0.021340**	**8.613524**	**0.0000**
FISKALNI KAPACITET	0.020639	0.005380	3.835821	0.0001
PODUZ. AKTIVNOST	0.002728	0.001056	2.583632	0.0098
NEZAPOSLENOST	-0.333220	0.298894	-1.114843	0.2649
Error Distribution				
SCALE:C(6)	0.305748	0.006026	50.73618	0.0000

Mean dependent var	0.299019	S.D. dependent var	0.293627
S.E. of regression	0.282734	Akaike info criterion	0.692470
Sum squared resid	120.3871	Schwarz criterion	0.713586
Log likelihood	-517.5073	Hannan-Quinn criter.	0.700333
Avg. log likelihood	-0.342267		
Left censored obs	0	Right censored obs	138
Uncensored obs	1374	Total obs	1512

Izvor: izračun autora; ispis Eviews9

Rezultati pokazuju kako je procijenjeni koeficijent uz varijablu *sjedište županije* pozitivan, što je u skladu s očekivanjem. P-vrijednost ukazuje kako je učinak ove varijable na pokazatelj učinkovitosti upravljanja nekretninama statistički signifikantan. Kontrolne varijable fiskalni kapacitet i poduzetnička aktivnost imaju statistički značajan učinak na pokazatelj učinkovitosti upravljanja nekretninama, s očekivanim predznakom, dok učinak pokazatelja nezaposlenosti nije statistički signifikantan.

Zaključno, usporedba medijana pokazuje kako je medijan pokazatelja učinkovitosti u gradovima koji su sjedišta županija značajno veći od medijana ostalih gradova, dok panel-Tobit model pokazuje kako varijabla *sjedište županije* ima pozitivan i statistički signifikantan utjecaj na pokazatelj učinkovitosti upravljanja nekretninama. **Na temelju navedenog može se zaključiti kako gradovi koji su sjedišta županija učinkovitije upravljaju nekretninama u svojem vlasništvu, što potvrđuje hipotezu H4.**

5.3.5. Utjecaj primjene modela projekta Reforme lokalne samouprave na učinkovitosti upravljanja nekretninama u hrvatskim gradovima

Kako je objašnjeno u prethodim dijelovima rada, u Republici Hrvatskoj je od 2001. do 2007. za potrebe Vlade implementiran projekt Reforme lokalne samouprave (PRLS) kojeg je razvio The Urban Institute iz Washingtona, po narudžbi USAID-a. Cilj je projekta bio ojačati upravljačke kapacitete lokalne samouprave kroz pet modula: (1) upravljanje financijama, (2) upravljanje imovinom, (3) gospodarski razvoj, (4) sudjelovanje građana i (5) informacijski sustavi.

Model "Upravljanje imovinom" cjelovito je sagledavao upravljanje – od popisa imovine (inventura), analize statusa vlasništva i klasifikacije svih pojavnih oblika, prije svega nekretnina, do procjene tržišne vrijednosti nekretnina i učinkovitosti upravljanja mjerene stopom kapitalizacije. Za takvo mjerenje nužno je znati sve izvore prihoda i troškove koji se na nekretnini ostvaruju. Važan je dio modela sagledavanje postojećih odluka, sustava izvještavanja, načina organizacije i, u zadnjem koraku, strateško planiranje upravljanja imovinom gradova. Model za upravljanje imovinom temelji se na dobroj međunarodnoj praksi koju su pripremili stručnjaci The Urban Instituta iz Washingtona na zahtjev Svjetske banke, a primjenjuje se u zemljama Europe i Azije (Kaganova et al., 2006), kao i u Hrvatskoj.

Zbog očekivanja da implementacija PRLS modela nositeljima gradske vlasti može pomoći da bolje gospodare nekretninama u vlasništvu gradova, ***hipoteza H5 pretpostavlja da je upotrebom modela Upravljanja imovinom iz projekta Reforme lokalne samouprave moguće povećati učinkovitost upravljanja nekretninama koje su u vlasništvu hrvatskih gradova.***

Peta hipoteza testira se prethodno objašnjenim panel-Tobit modelom, koji kao glavnu objašnjavajuću varijablu uključuje binarnu varijablu *PRLS*, koja poprima vrijednost 1 u slučaju da je grad implementirao PRLS model i 0 u slučaju da nije, uz odgovarajuće kontrolne varijable, fiskalni kapacitet gradova, poduzetničku aktivnost u gradovima te pokazatelj nezaposlenosti. Rezultati panel-Tobit modela prikazani su u Tablici 5.17.

Tablica 5-17 Rezultati panel-Tobit modela na uzorku svih gradova – PRLS model

Dependent Variable: EF
Method: ML - Censored Normal (TOBIT) (Newton-Raphson / Marquardt steps)
Sample: 2005 2016
Included observations: 1512
Left censoring (value) series: 0
Right censoring (value) series: 1
Convergence achieved after 4 iterations
Coefficient covariance computed using observed Hessian

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.214383	0.035274	6.077652	0.0000
PRLS	**0.027838**	**0.035563**	**0.782768**	**0.4338**
FISKALNI KAPACITET	0.019360	0.005523	3.505357	0.0005
PODUZ. AKTIVNOST	0.002920	0.001089	2.681627	0.0073
NEZAPOSLENOST	-0.303763	0.306864	-0.989897	0.3222
Error Distribution				
SCALE:C(6)	0.313573	0.006182	50.72209	0.0000

Mean dependent var	0.299019	S.D. dependent var	0.293627
S.E. of regression	0.290055	Akaike info criterion	0.740115
Sum squared resid	126.7027	Schwarz criterion	0.761231
Log likelihood	-553.5267	Hannan-Quinn criter.	0.747978
Avg. log likelihood	-0.366089		
Left censored obs	0	Right censored obs	138
Uncensored obs	1374	Total obs	1512

Izvor: izračun autora; ispis Eviews9

Rezultati pokazuju kako je procijenjeni koeficijent uz varijablu *PRLS* pozitivan, što je u skladu s očekivanjem. Međutim, vrijednost ukazuje na to da je učinak ove varijable na pokazatelj učinkovitosti upravljanja nekretninama statistički signifikantan. Kontrolne varijable fiskalni kapacitet i poduzetnička aktivnost imaju statistički značajan učinak na pokazatelj učinkovitosti upravljanja nekretninama, s očekivanim predznakom, dok učinak pokazatelja nezaposlenosti nije statistički signifikantan.

Na temelju navedenog ne može se zaključiti kako gradovi koji su implementirali PRLS model učinkovitije upravljaju nekretninama u svojem vlasništvu pa se hipoteza H5 ne može potvrditi.

Međutim, pri interpretaciji ovog zaključka treba voditi računa da je samo 19 od 126 gradova (15% ukupnog uzorka) implementiralo PRLS model, što može utjecati na procjenu značajnosti

primjene ovog modela upravljanja imovinom na učinkovitost upravljanja nekretninama u hrvatskim gradovima.

5.4. Ograničenja istraživanja i preporuke za buduća istraživanja

Temeljna ograničenja ovog istraživanja proizlaze iz relativno ograničene vremenske dimenzije uzorka (od 2005. do 2016. godine), koji je određen dostupnošću podataka. Iako je broj opažanja u pojedinačnim opservacija relativno visok, problem je što se analiza provodi na periodu koji je značajno obilježen recesijom, koja je u Hrvatskoj trajala od 2009. do 2014. godine (50% ukupnog perioda). Recesija je značajno utjecala na prihode od imovine, fiskalni kapacitet, gospodarsku aktivnost i cijene nekretnina u Hrvatskoj što se odražava i na podatke korištene u ovoj analizi. Istraživanje bi bilo uputno ponoviti za nekoliko godina kada će biti dostupan veći broj podataka.

Dodatno ograničenje istraživanja proizlazi iz definiranog DEA modela kojim je izračunata središnja varijabla ove disertacije – pokazatelj učinkovitosti korištenja nekretnina u gradovima. Predloženi model u ovom radu koristi samo jedan input i samo jedan input. U budućim istraživanjima može se koristiti kompleksniji DEA model koji bi uključivao veći broj inputa i veći broj outputa. Može se koristiti i model orijentiran na inpute, za razliku od modela orijentiranog na outpute u ovom radu, ako se smatra da nositelji politike u lokalnim jedinicama mogu relativno snažno i često utjecati na vrijednost nekretnina u vlasništvu gradova. Također, osim DEA modela moguće je koristiti i druge metode mjerenja učinkovitosti, poput FDH modela (eng. Free Disposable Hull) ili SFA modela (eng. Stochastic Frontier Analysis). Dodatno, pokazatelj učinkovitosti može se definirati i prema standardnim računovodstvenim pokazateljima, poput povrata na imovinu (ROA).

U Tobit-panel analizi korišten je određeni broj kontrolnih varijabli, a njihov se broj može proširiti. Također, u budućim se istraživanjima neke kontrolne varijable iz ovog rada mogu koristiti kao glavne objašnjavajuće varijable budući da empirijska i teorijska literatura ukazuje na njihovu značajnost za upravljanje nekretninama u gradovima. U budućim se istraživanjima također može koristiti i panel-Tobit model s fiksnim efektima koji bi služili da procijene učinke opažene heterogenosti među gradovima.

6. ZAKLJUČAK

Upravljanje nekretninama u vlasništvu gradova u Republici Hrvatskoj, kao i u dobrom dijelu regije, veliki je izazov u svakom pogledu – kao pravni okvir, kao kontinuitet u razvoju društva, kao značajno tranzicijsko pitanje, kao metodologija evidentiranja i dokazana dobra praksa upravljanja.

Dvadesetak godina sustava upravljanja imovinom u gradovima nije dostatno da se na vidjelu pokažu i dokažu najbolje prakse u postojećim zakonskim okvirima. Naime, evidentno je da svaka institucija koja se bavi predmetima vezanim za nekretnine – Ministarstvo državne imovine, Ministarstvo financija, Ministarstvo graditeljstva i prostornog uređena, Državni ured za reviziju, Državna geodetska uprava, zemljišnoknjižni odjeli i mnogi drugi uredi, agencije i službe, imaju svaki svoj pogled na nekretnine gradova. Za neke institucije to je samo geoprostorna jedinka – objekt na terenu, za neke stavka kontnog plana, a za neke resurs sa sjajnim potencijalom koji treba vlasniku donijeti značajne koristi (prihode).

Čelnicima gradova sigurno je teško snaći se u svemu tome, pa otuda i nesnalaženje nižih razina u pogledu pristupa upravljanja nekretninama u vlasništvu gradova. Nesnalaženje ide do te razine da se dobiva dojam kao da im je sva ta imovina teret i da bi radije da je imaju što manje. Čelnika zanima jedan aspekt – često iz perspektive promatranja javnog interesa, a ne financijskog rezultata, reviziju drugi – je li se učinkovito upravlja imovinom, referenta dugotrajne imovine pak treći aspekt.

Za čelnika je to izazov i upravo se na njegovom razmišljanju u zadanim zakonskim okvirima postiže bolji rezultat ili on izostaje. Čelnik treba razmišljati i odlučivati kao *manager*, a za to mu trebaju upravo i takvi (*managerski*) alati. Uloga gradova i mogućnost različitog korištenja pojedinih vrsta nekretnina svakako bi pomogla kada bi bila jasna po svojim funkcionalnim zahtjevima. Znači, za čelnika i njegove službe ključno je da svaka nekretnina dobije pravu funkciju – da se koristi, da nije prazna, da nije dana na korištenje korisnicima koji svojom djelatnošću, programima i projektima ne opravdavaju vrijednost izgubljenog zakupa.

Učinkovitost upravljanja nekretninama u ovom je radu analizirana korištenjem dviju analitičkih metoda. U prvom je koraku provedena analiza omeđivanja podataka (DEA) korištenjem DEA modela orijentiranog na output, s pretpostavkom varijabilnih prinosa na opseg, korištenjem jednog inputa i jednog outputa. Kao input varijabla odabrana je vrijednost nekretnina u

gradovima po stanovniku, a kao output varijabla odabran je prihod od nekretnina po stanovniku iz gradskih proračuna. Logika ovakvog pristupa proizlazi iz činjenice da se gospodarenje nekretninama u gradovima očituje kroz prihode koje gradovi kroz njih ostvaruju. Odabrani je model orijentiran na outpute budući da se pretpostavlja da gradovi (u kratkom roku) lakše upravljaju prihodima (kroz najamnine, zakupe, koncesije i sl.) nego samom vrijednošću nekretnina u svojem vlasništvu (kupoprodaja nekretnina je relativno kompleksan posao, a gradovi u praksi nemaju običaj prodavati značajan dio portfelja nekretnina). Na temelju DEA modela izračunat je pokazatelj učinkovitosti upravljanja nekretninama u gradovima, pri čemu je važno istaknuti kako je za svaku skupinu gradova (mali, srednje veliki i veliki) izračunat zaseban pokazatelj učinkovitosti upravljanja nekretninama.

Usporedbom medijana pokazatelja učinkovitosti (i odgovarajućih procijenjenih intervala pouzdanosti medijana) u ovom istraživanju su definirani različiti zaključci koji daju relevantan znanstveni i aplikativni doprinos u području lokalnih financija. Znanstveni doprinos proizlazi iz analitičkog pristupa definiranju pokazatelja učinkovitosti upravljanja nekretninama, koji do sada nije korišten u literaturi, dok aplikativni doprinos proizlazi iz mogućnosti korištenja ovih rezultata u daljnjim analizama te korištenja rezultata kao podloge za kreiranje preporuka nositeljima politike na lokalnoj razini.

Rezultati ovog dijela istraživanja upućuju na nekoliko važnih zaključaka. Prvo, utvrđeno je kako gradovi u Republici Hrvatskoj ne upravljaju učinkovito nekretninama u svojem vlasništvu. U skupini malih gradova samo 12% gradova upravlja učinkovito nekretninama u svojem vlasništvu, u skupini srednje velikih 9%, a u skupini velikih 24% gradova, pri čemu se kao referentna vrijednost učinkovitog upravljanja koristi vrijednost pokazatelja učinkovitosti iznad 0,9, što je standard u srodnoj literaturi. Sljedeće, pokazano je kako veliki gradovi učinkovitije upravljaju nekretninama u svojem vlasništvu od malih i srednje velikih gradova. Konkretno, u skupini velikih gradova postotak gradova koji učinkovito upravljaju nekretninama u svojem vlasništvu značajno je veći u odnosu na male i srednje gradove. Najniže vrijednosti pokazatelja učinkovitosti u skupini velikih gradova značajno su veće od najnižih vrijednosti pokazatelja učinkovitosti u skupinama malih i srednjih gradova, dok je medijan pokazatelja učinkovitosti u skupini velikih gradova značajno veći od medijana pokazatelja učinkovitosti u skupinama malih i srednje velikih gradova. Veliki gradovi zakonom imaju definirano širi popis

obaveza i usluga koje moraju pružati privatnim i pravnim osobama sa svojeg područja. Slijedom navedenog, imaju potrebu ustrojiti organizacijske jedinice te ih kadrovski ekipirati kako bi mogli izvršavati sve zakonom definirane obaveze i dužnosti. Veći broj zaposlenika gradske uprave s određenim stručnim znanjima i iskustvom koji su zaposleni u resornim upravnim odjelima i/ili odsjecima mogu doprinijeti kvalitetnijem upravljanju nekretninama koje su u vlasništvu grada. Rezultati usporedbe medijana također su pokazali kako gradovi koji su smješteni na obali učinkovitije upravljaju nekretninama u svojem vlasništvu od ostalih gradova. Gradovi koji lokacijom zadovoljavaju uvjet da su smješteni uz morsku obalu svojim položajem predstavljaju veći turistički potencijal u odnosu na gradove koji nisu smješteni uz more. Veća vrijednost nekretnina kao i potražnja za njima upravo na ovakvim lokacijama dolazi do izražaja i omogućuje vlasnicima bolje prinose. Sukladno tome gradovi koji su smješteni uz more uložit će veće resurse u svoje nekretnine kako bi maksimalno iskoristili njihov potencijal. Konačno, usporedba medijana je pokazala kako je medijan pokazatelja učinkovitosti u gradovima koji su sjedišta županija značajno veći od medijana ostalih gradova. Gradovi županijska središta su jedinice lokalne samouprave koje zbog svoj položaja i normativnog uređenja predstavljaju središta svog regionalnog područja čime takvim položajem jačaju društveni utjecaj i gospodarsku aktivnosti u tom području. U gradovima koji su sjedišta županija moguće je konzumirati usluge određenih funkcija središnje države koje su prenesene na županijska središta. Sukladno navedenom, u županijskim središtima nalaze se relevantne institucije, a samim time i nekretnine su u funkciji upravljanja županijama. Ti su gradovi često i kulturna središta županija, čime se dodatno povećava iskorištenost nekretnina (kazališta, kina, muzeji, udruge i sl.). Navedeni gradovi često su i sjedišta poduzeća, a i većina svakodnevnog poslovanja koncentrirana je u njima, čime se povećava i broj gradskih i drugih prostora koji se koriste u poslovne svrhe. U svim navedenim rezultatima važno je istaknuti kako su sve varijable normalizirane brojem stanovnika te kako su osim samih medijana uspoređene i granice intervala pouzdanosti, što rezultatima daje analitički kredibilitet.

Osim usporedbe medijana (i intervala pouzdanosti) u ovom je radu provedena i panel-Tobit analiza kako bi se dodatno utvrdio utjecaj pojedinih obilježja gradova na pokazatelj učinkovitosti upravljanja nekretninama u gradovima. Znanstveni doprinos ovog dijela istraživanja također proizlazi iz analitičkog pristupa definiranju pokazatelja učinkovitosti upravljanja nekretninama, koji do sada nije korišten u literaturi, te produbljivanja znanstvenih spoznaja o odrednicama učinkovitosti upravljanja nekretninama u gradovima.

Kao glavne objašnjavajuće varijable u panel modelima korištene su lokacija (nalazi li se grad na obali ili ne), sjedište županije (je li grad sjedište županije ili nije) te PRLS model (je li grad implementirao PRLS model upravljanja imovnom ili nije). Osim glavnih objašnjavajućih varijabli u modelima su korištene i pojedine kontrolne varijable. Skup kontrolnih varijabli koje su bile uključene u ovo istraživanje su nezaposlenost stanovništva, kao važan pokazatelj stadija poslovnog ciklusa, broj poduzetnika po stanovniku kao pokazatelj poduzetničke aktivnosti te fiskalni kapacitet koji prikazuje fiskalnu moć pojedinog grada. Kontrolne varijable imaju važnu ulogu u panel analizama jer one procjenjuju učinak važnih obilježja gradova (gospodarska situacija u gradu, snaga poduzetničke aktivnosti u gradu i fiskalni kapaciteta grada) na učinkovitost upravljanja nekretninama i smanjuju mogućnost izostavljanja važnih varijabli iz modela (eng. omitted variable bias).

Rezultati panel-Tobit modela potvrdili su kako gradovi koji su sjedišta županija učinkovitije upravljaju gradovima u svojem vlasništvu od ostalih gradova u Republici Hrvatskoj. S druge strane, provedena panel analiza pokazala je kako lokacija ima statistički značajan učinak na učinkovitost upravljanja nekretninama samo u skupini srednje velikih gradova, dok u ostalim gradovima ovaj učinak nije statistički signifikantan. Ovakvi rezultati mogu se protumačiti činjenicom da je relativno mali broj velikih i malih gradova smješten na obali te da definicija varijable (binarna) bez varijacije kroz vrijeme ne može adekvatno odraziti učinak u ovako definiranom modelu, što je važan zaključak za buduća istraživanja. Konačno, rezultati panel analize pokazali su da primjena PRLS modela ima pozitivan učinak na učinkovitost upravljanja nekretninama u vlasništvu gradova, ali da taj učinak nije statistički signifikantan. Međutim, pri tumačenju ovog rezultata važno je imati na umu činjenicu da je u promatranom razdoblju samo 19 od 126 gradova (15% ukupnog uzorka) implementiralo PRLS model, što može utjecati na empirijsku procjenu značajnosti primjene ovog modela upravljanja imovinom na učinkovitost upravljanja nekretninama u hrvatskim gradovima.

U aktivnostima upravljanja gradskim nekretninama od velike je važnosti voditi računa i o nekretninama u vlasništvu javnih ustanova kojima je grad osnivač, jer se, usprkos činjenici da su javne ustanove često vlasnici nekretnina koje koriste, troškovi održavanja i poboljšavanja istih vrlo često podmiruju upravo na teret gradskog proračuna. Nažalost, pored obavljanja poslova iz svoje zakonske nadležnosti, odnosno aktiviranja nekretnina u smislu stjecanja

prihoda i njihove gospodarske iskoristivosti, ponekad se nekretnine mogu naći u ulozi sredstva osiguranja različitih tražbina na način da se na njima osnuje prisilno ili dobrovoljno založno pravo. Takve je okolnosti potrebno evidentirati i pratiti s obzirom na to da mogu biti od značajnog utjecaja na raspolaganje i upravljanje nekretninama u najširem smislu.

Financijska politika gradova u procesu upravljanja nekretninama u njihovom vlasništvu treba težiti smanjenju potrošnje proračunskog novca na nekretnine u vlasništvu gradova, ali zadržavanju njihove vrijednosti te kvalitete i brojnosti usluga koje se pružaju korištenjem navedenih nekretnina. S druge strane teži se povećanju prihoda, ali bez narušavanja aktivnosti privatnog sektora i potreba tržišta te sukoba s postojećom socijalnom politikom.

S obzirom na raznolikost nekretnina u vlasništvu gradova te brojnost portfelja (različitih vrsta nekretnina), a u skladu s ciljevima financijske politike vezane za tu vrstu imovine, daljnje upravljanje treba temeljiti na načelima:

- maksimalizirati učinkovitost nekretnina
- minimizirati troškove zadržavajući kvalitetu nekretnina na zadovoljavajućoj razini
- identificirati, analizirati i minimizirati indirektne subvencije na sve nekretnine
- maksimizirati neto prihode i primijeniti tržišne principe u upravljanju nekretninama.

Prihodi od nekretnina obuhvaćaju među ostalim prihode od prodaje, zakupa, najma, prava služnosti, prava građenja i naknade štete s osnove osiguranja. U skladu s navedenim neto prihode ostvarene od raspolaganja nekretninama mora se ulagati u projekte poput kupovine novih jedinica imovine te održavanja postojećih radi poboljšanja kvalitete imovine s ciljem kvalitetnijih usluga za građane. U koje će se projekte kapitalnih investicija ulagati, određivat će se u skladu s planom i prioritetima kapitalnih investicija te nekim od navedenih načela:

- Neto prihode od prodaje nekretnina ulagati u projekte kapitalnog investiranja, održavanja postojećih ili kupovinu novih jedinica imovine.
- Prihode od korištenja nekretnina ulagati u upravljanje, operativno održavanje i kupovinu novih jedinica imovine.

Postavljajući pitanje treba li nekretninama u vlasništvu gradova upravljati lokalno ili na razini središnje države, dileme zapravo da i nema. Ili zapravo ima, ovisno o kojoj se vrsti nekretnina radi i tko je njihov korisnik. Naravno, ako su u pitanju vojni objekti, državna infrastruktura i

mnoge druge, onda je to zadatak središnje države da organizira upravljanje tim vrstama nekretnina. No ako se radi o svim ostalim nekretninama koje su lokalnog značaja i dometa, onda to treba prepustiti gradovima jer su one dnevno s njima u nekakvom aktivnom odnosu. Država treba samo propisati pravila, tj. dobar pravni okvir. No nije samo propisivanje normi dovoljno za uspješnost upravljanja nekretninama, već u praksi potvrđena primjena najboljih rješenja.

Kako je uvijek opasna varijantnost odnosno dvostruki kriterij (lokalno ili središnje), tako su upitni i rezultati obuhvata Središnjeg registra državne imovine koji predstavlja sveobuhvatnu i cjelovitu, metodološki standardiziranu i kontinuirano ažuriranu evidenciju državne imovine. Naime, kako je po Zakonu o središnjem registru državne imovine (NN 112/2018) i imovina lokalne samouprave državna imovina, to je i obveza gradova da dostavljaju podatke i promjene istih u Središnji registar.

Jasna je potreba središnje države da na jednom mjestu ima evidentiranu cjelokupnu imovinu (npr. zbog konsolidirane bilance i iskazivanja sveukupne vrijednosti imovine), no previše je godina prošlo (preko 25) a da se taj cilj još nije ni blizu ostvario. Svaka dosadašnja vlast ima svoj novi pristup, novu strategiju, nove ciljeve, promijenjene uloge lokalne samouprave u odnosu na središnju državu, a imovina i dalje ostvaruje upitne rezultate.

Nesumnjivo je da su velika ulaganja gradova u infrastrukturne nekretnine značajno poboljšala uvjete za brži gospodarski razvoj koji jedino može dati potrebnu dodanu vrijednost za budućnost (zapošljavanje, viši standard). S druge strane veliki sportski ili kulturni objekti, teško daju potrebne povrate (bar u kratkoročnom periodu), te na taj način predstavljaju i velika financijska opterećenja za gradove u kojima se nalaze. Veliki utjecaj na način korištenja nekih vrsta nekretnina imaju i društvene promjene i trendovi. Npr. nekada su društveni (zadružni) domovi imali veliki značaj za lokalnu zajednicu. To je bila vrsta nekretnina koja se koristila dnevno za razne kulturne (zabave, plesne večeri, kino, dvorana za svečanosti) i političke događaje, za okupljanje i organizaciju lokalne zajednice, za mjesto razmjene dobara (otkup poljoprivrednih proizvoda). Danas su to u gotovo 90% napušteni objekti ili u najboljem slučaju prenamijenjeni za neke druge potrebe.

Tranzicijskim promjenama unazad 25 godina, nastale su značajne promjene u pristupu upravljanja nekretninama gradova, pri čemu se postižu spori napredci u ispunjenju temeljnog uvjeta za uspješnije upravljanje nekretninama, a to je sređene evidencije o vrsti, namjeni, broju, vrijednosti, te prihodima i rashodima na imovini.

Bez sređenih evidencija o nekretninama nemoguće je istima učinkovito upravljati. Nadalje, sređivanje evidencija, javno provođenje svih postupaka vezanih za upravljanje i raspolaganje (zakupi, najmovi, zamjene, prodaje, korištenje s valjanom pravnom osnovom i dr.), izuzetno je bitno za transparentno upravljanje koje građani mogu prepoznati i dati sasvim drugačiju podršku lokalnoj vlasti (kroz izbore, referendume, ali i druge oblike odlučivanja). Na taj se način dostiže potrebna kontrola i odgovornost na procesima upravljanja i raspolaganja nekretninama, koju izuzetno brzo može prepoznati i privatni sektor u kontekstu povjerenja za ulaganja i gospodarski razvoj, što dalje znači povećano zapošljavanje i sveukupni viši standard života u lokalnoj zajednici. Svakako da gradovi nisu jedini subjekt koji može o svemu odlučiti oko učinkovitijeg upravljanja i raspolaganja svojim nekretninama.

POPIS LITERATURE

1. Abdullah, S., Abdul Razak, A., & Hamid Kadir Pakir, A. (2011). The characteristics of real estate assets management practice in the Malaysian Federal Government. *Journal of Corporate Real Estate*, *13*(1), 16-35.
2. Ahlheim, M. (2002). Mjerenje troškova obnove i razvoja devastiranih područja. *Financijska teorija i praksa*, *26*(3), 691-711.
3. Alhazmi, N. M. (2014). *Improving asset management in the public sector in the Kingdom of Saudi Arabia* (Doctoral dissertation, University of Leeds).
4. Ayuningtiyas, R. (2008, 18 Juni 2008). Traffic jam in Semanggi, road user choose to pull over. *Kompas*. Pristupljeno 10 travnja 2018, http://www.kompas.com/read/xml/2008/06/18/14413869/semanggi.macet.motor.pilih.menepi.
5. Bajo, A. (1998). Financiranje lokalnih jedinica zaduživanjem. *Financijska praksa*, *22*(4-5), 469-490.
6. Bajo, A. (1999). Zašto i kako mjeriti fiskalni kapacitet lokalnih jedinica. *Financijska praksa*, *23*(3), 277-308.
7. Bajo, A. (2011). Capital investment plans and local government debt in Croatia. *Newsletter: povremeno glasilo Instituta za javne financije*, *13*(54), 1-10.
8. Bajo, A. (2013). Upravljanje imovinom i obvezama javnog sektora. *Aktualni osvrti, Institut za javne financije, br, 50*, 18.
9. Banner, D. K., & Gagne, T. E. (1995). *Designing effective organizations: Traditional & transformational views*. Thousand Oaks, Calif: Sage Publications.
10. Barra, C., & Zotti, R. (2014). Handling negative data using Data Envelopment Analysis: a directional distance approach applied to higher education.
11. Barra, C., Lagravinese, R., & Zotti, R. (2015). Explaining (in) efficiency in higher education: a comparison of parametric and non-parametric analyses to rank universities.
12. Bartulović, V. (2016). Učinkovito pružanje usluga od općeg interesa–od javnog prema privatnom upravljanju: završni rad (Doctoral dissertation, University of Split. Faculty of economics Split.).
13. Bertović, H., Kaganova, O., Rutledge, J., & PRIRUČNIK, Z. (2004). Upravljanje imovinom u jedinicama lokalne i područne (regionalne) samouprave'. *The Urban Institute i Savez Udruge gradova i Udruge općina Republike Hrvatske, Zagreb*.

14. Bogović, N. D. UPRAVLJANJE LOKALNIM EKONOMSKIM RAZVOJEM–PRIMJER OPĆINE BALE. *Ekonomika i menadžment u javnom sektoru*, 7.
15. Bogović, T. (2014). *Assessment of the Efficiency of Croatian Cities Using Data Envelopment Analysis (DEA)* (Doctoral dissertation, Fakultet organizacije i informatike, Sveučilište u Zagrebu).
16. Bond, S., & Dent, P. (1998). Efficient management of public sector assets The call for correct evaluation criteria and techniques. *Journal of Property Valuation and Investment*, *16*(4), 369-385.
17. Boras, T., & Tica, J. (2013). Prostorna elastičnost traženih cijena stanova na stambenom tržištu Grada Zagreba. *EFZG working paper series*, (04), 1-21.
18. Botrić, V., & de Villa, Ž. K. (2005). Determinants of Regional Housing Market in Croatia.
19. Bratić, V. (2008). Odlučivanje o lokalnim proračunima: između sna i jave. Inst. za Javne Financije.
20. Bronić, M., Ott, K., & Urban, I. (2012). Local budget transparency: the case of 33 Croatian cities. *Financial theory and practice*, *36*(4), 355-371.
21. Brummerhoff, D. (2000). Javne financije, 7., potpuno prerađeno izdanje. *Mate doo, Zagreb*.
22. Campbell, J. D., Jardine, A. K., & McGlynn, J. (Eds.). (2016). *Asset management excellence: optimizing equipment life-cycle decisions*. CRC Press.
23. Coelli, T. (1996) "A guide to DEAP version 2.1: a data envelopment analysis (computer) program. Centre for Efficiency and Productivity Analysis", *University of New England*, Australia
24. Croatia, U. S. A. I. D. (2006). Učinkovito financiranje kapitalnih ulaganja u jedinicama lokalne samouprave (vodič za učinkovito upravljanje procesom kapitalnih ulaganja). *Zagreb, Urban Institute*.
25. Čulo, I., Mahaček, D., & Šubat-Stilinović, A. (2013). Management of self-government unit assets. *Vještak*, *33*(1-2), 315.
26. Deininger, K., & Feder, G. (2009). Land registration, governance, and development: Evidence and implications for policy. *The World Bank Research Observer*, *24*(2), 233-266.
27. Dent, P. (2002). Modernising government: a new way to manage property assets?.
28. Dent, P. (2014). "Managing public sector property assets: the valuation issues", *Property Management*, Vol. 15 Iss 4 pp., 226 – 233.

29. Državni ured za reviziju (2013). Izvješća o radu Državnog ureda za reviziju za 2012. Zagreb: Državni ured za reviziju.
30. Državni ured za reviziju (2014). Izvješća o radu Državnog ureda za reviziju za 2013. Zagreb: Državni ured za reviziju.
31. Državni ured za reviziju (2016). Izvješće o obavljenoj reviziji učinkovitosti upravljanja i raspolaganja nekretninama jedinica lokalne i područne (regionalne) samouprave, dostupno na: http://www.revizija.hr/izvjesca/2016/rr-2016/revizije-ucinkovitosti/upravljanje-i-raspolaganje-nekretninama-lokalnih-jedinica/upravljanje-i-raspolaganje-nekretninama-skupno-izvjesce.pdf
32. Državni ured za upravljanje državnom imovinom (2016) Revidirani strateški plan Državnog ureda za upravljanje državnom imovinom za razdoblje 2016.-2018., dostupno na: https://imovina.gov.hr/UserDocsImages/dokumenti/Prijedlog%20Plana%20upravljanja%20imovinom/Strategina%202018-2020.pdf
33. Edwards, V., & Ellison, L. (2009). *Corporate property management: aligning real estate with business strategy*. John Wiley & Sons.
34. European Commission (2004): "European Competitiveness Report 2004", Commission Staff Working Document SEC(2004)1397, Brussels: European Commission.
35. Farrell, M. J. (1957). The measurement of productive efficiency. *Journal of the Royal Statistical Society: Series A (General)*, *120*(3), 253-281.
36. Fruk, Ž. (2015). Specifičnosti upravljanja državnom imovinom u Republici hrvatskoj uz osvrt na međunarodna iskustva. *Praktični menadžment: stručni časopis za teoriju i praksu menadžmenta*, *6*(1), 147-151.
37. Garmendia, C., & Kapur, A. (2013). Enhancing Government Property Management with Data and Technology.
38. Gorzelany-Plesińska, J., & Rewkowska, M. (2015). Management of communal land and property resources in the context of municipal development–the example of Bobolice municipality. *Geomatics, Landmanagement and Landscape*.
39. Grad Karlovac (2007) Strateški plan upravljanja imovinom Grada Karlovca. LC tim i The Urban Institute.
40. Greer, G. E., & Kolbe, P. T. (2003). *Investment analysis for real estate decisions* (Vol. 1). Dearborn Real Estate.
41. Grover, R. (2009). State and public land management: the drivers of change. *Land reform journal. January*.

42. Grubišić, M., Nušinović, M., & Roje, G. (2009). Prema učinkovitom upravljanju državnom imovinom. *Financijska teorija i praksa*, *33*(3), 335-374.
43. Guszak, I. (2007). IT services outsourcing-real estates registry. In *Outsourcing u gradovima i općinama*. The Urban Institute.
44. Guszak, I. (2008a). Model logističke podrške upravljanju nekretninama u vlasništvu jedinica lokalne samouprave. *Ekonomski pregled*, *59*(7-8), 469-493.
45. Guszak, I. (2008b). Creating added value by applying logistics principles in management of local government owned real estates. In *An Enterprise Odyssey. International Conference Proceedings* (p. 1027). University of Zagreb, Faculty of Economics and Business.
46. Hajnal, I. (2016). Applicability of the EN 15221 standard in Public Facility Management. *Procedia engineering*, *164*, 277-283.
47. Hanis, M. H., Trigunarsyah, B., & Susilawati, C. (2010a). The significant of public asset management framework application for Indonesian local governments: Opportunities and challenges. In *Proceedings of 1st Makassar International Conference On Civil Engineering*.
48. Hanis, M. H., Trigunarsyah, B., & Susilawati, C. (2010b). Public asset management framework for local governments: Opportunities and challenges for public asset managers. In *Proceedings of 2nd International Postgraduate Conference on Infrastructure and Environment*. Hong Kong Polytechnic University.
49. Harvey, D. (2001). *MegaCities: lecture 4*. Twynstra Gudde Management Consultants.
50. Hasbi Hanis, M., Trigunarsyah, B., & Susilawati, C. (2011). The application of public asset management in Indonesian local government: A case study in South Sulawesi province. *Journal of Corporate Real Estate*, *13*(1), 36-47.
51. Hentschel, J., & Kaganova, O. (2007). Government property resources: A case for asset management. *Public Management (00333611)*, *89*(2), 24-26.
52. Hood, C. (1991). A public management for all seasons?. *Public administration*, *69*(1), 3-19.
53. Hunjak, T., & Jakovčević, D. (2003). Višekriterijski modeli za rangiranje i uspoređivanje banaka. *Zbornik Ekonomskog fakulteta u Zagrebu*, *1*(1), 43-60.
54. Jacobs, R., Smith, P. C., & Street, A. (2006). *Measuring efficiency in health care: analytic techniques and health policy*. Cambridge University Press.
55. Jafarov, E., & Gunnarsson, V. (2008). Efficiency of government social spending in Croatia. *Financial theory and practice*, *32*(3), 289-320.

56. Jafarov, E., & Gunnarsson, V. (2008). Efficiency of government social spending in Croatia. *Financial theory and practice*, *32*(3), 289-320.
57. Jolicoeur, P. W., & Barrett, J. T. (2005). Coming of age: Strategic asset management in the municipal sector. *Journal of Facilities Management*, *3*(1), 41-52.
58. Jones, K., & White, A. D. (2008). RICS public sector asset management guidelines. *A guide to best practice. London, UK: Royal Institution of Chartered Surveyors*.
59. Kaganova, O. (2013). Government Management of Land and Property Assets: Justification for Engagement by the Global Development Community. *URL: www. urban. org/uploadedpdf/412286-Govt-Management-of-Land. pdf. Accessed on*, *12*.
60. Kaganova, O., McKellar, J., & Peterson, G. (2006). Introduction. In O. Kaganova & J. McKellar (Eds.),*Managing government property assets: International experiences* (1 ed., pp. 2). Washington, D.C. 20037: The Urban Institute Press.
61. Kaganova, O., Tian, V., & Undeland, C. (2001). Learning how to be efficient property owners and accountable governments: The case of Kyrgyzstan's cities. *Public Administration and Development: The International Journal of Management Research and Practice*, *21*(4), 333-341.
62. Kämpf-Dern, A., & Pfnür, A. (2014). Best practice, best model, best fit: Strategic configurations for the institutionalization of corporate real estate management in Europe. *Journal of Corporate Real Estate*, *16*(2), 97-125.
63. Kask, K. (2014). *Public sector real estate asset management models and their evaluation* (Doctoral dissertation).
64. Keefer, P. (2004). *A review of the political economy of governance: From property rights to voice* (Vol. 3315). World Bank Publications.
65. Kontrec, D. (2014) Pravni status i raspolaganje poljoprivrednim zemljištem u Republici Hrvatskoj – povijesni prikaz, *de lege lata, de lege ferenda*. *Radovi Zavoda za znanstveni rad* (25): 69-95.
66. Koopmans, T. C. (1951). An analysis of production as an efficient combination of activities. *Activity analysis of production and allocation*.
67. Kooymans, R., & Abbott, J. (2006). Developing an effective service life asset management and valuation model. *Journal of Corporate Real Estate*, *8*(4), 198.
68. Koprić, I. (2015) Otvorena pitanja rješavanja problema povrata imovine ili naknade za imovinu bivših zemljišnih zajednica. *Hrvatska i komparativna javna uprava* 15(2): 545-557.

69. Kordić, G., & Podborkić, R. (2010). Oporezivanje imovine: hrvatska praksa i europska iskustva. *Ekonomska misao i praksa*, (1), 105-120.
70. Koutsoyiannis, A., & Babić, A. (1996). *Moderna mikroekonomika*. Marketing-tehnologija.
71. Krtalić, S., & Škreblin, B. B. (2011, January). Aspects of fiscal decentralisation in Croatia. In *International Scientific Conference" Entrepreneurship and Macroeconomic Management"(5; 2011)*.
72. Lausberg, C., Müller, N., & Arnd, R. (2010). *Achieving Value Growth By Professionalizing Public Real Estate Management: Results And Conclusions From An Empirical Survey In Germany* (No. eres2010_274). European Real Estate Society (ERES).
73. Lijović, T. (2013). *Društveno odgovorno poslovanje u javnom sektoru* (Doctoral dissertation, Sveučilište Jurja Dobrile u Puli).
74. Loomis, J. B. (2002). *Integrated public lands management: principles and applications to national forests, parks, wildlife refuges, and BLM lands*. Columbia University Press.
75. Lu, Y. (2001). New Public Management reforms in public asset management as the state governments of the United States. In *International Conference on Public Administration (ICPA th)*.
76. Lu, Y. (2011). *Public Asset Management: Empirical evidence from the state governments in the United States*. Florida Atlantic University.
77. Lu, Y. (2017). Public capital asset management: A holistic perspective. *Journal of Public Procurement*, *17*(4), 483-524.
78. Lu, Y., & Wang, H. (2010). State-owned asset management reform in China. In *4th International Public Procurement Conference (IPPC2010) Proceedings, August* (pp. 26-28).
79. Mačkić, V. (2014). Political budget cycles at the municipal level in Croatia. *Financial theory and practice*, *38*(1), 1-35.
80. Manase, D. (2015). *Public Sector Property Asset Management*. John Wiley & Sons.
81. Maras, P. (2015). *Ustrojstvo lokalne samouprave u Gradu Rijeci* (Doctoral dissertation, Polytechnic" Nikola Tesla" in Gospić. Administrative department.).
82. Mardiasmo, D. (2012). *State asset management reform in Indonesia: a wicked problem* (Doctoral dissertation, Queensland University of Technology).
83. Mardiasmo, D., Sampford, C., & Barnes, P. (2012). The exemplification of governance principles within state asset management laws and policies: the case of Indonesia. In

Engineering Asset Management and Infrastructure Sustainability (pp. 613-631). Springer, London.

84. Marona, B., & van den Beemt-Tjeerdsma, A. (2018). Impact of Public Management Approaches on Municipal Real Estate Management in Poland and The Netherlands. *Sustainability*, *10*(11), 4291.
85. Međunarodni monetarni fond (2001): Government Financial Statistics Manual. Washington, DC: International Monetary Fund.
86. Mihaljek, D. (2005). *Free movement of capital, the real estate market and tourism: a blessing or a curse for Croatia on its way to the European Union?* (pp. 185-228). Anderes Land.
87. Ministarstvo državne imovine (2018) Revidirani strateški plan Ministarstva državne imovine za razdoblje 2018.-2020., dostupno na: https://imovina.gov.hr/UserDocsImages/dokumenti/Izvjesca/Revidirani%20strate%C5%A1ki%20plan%20Dr%C5%BEavnog%20ureda%20za%20upravljanje%20dr%C5%BEavnom%20imovinom%20za%20razdoblje%202016-2018.pdf
88. Ministarstvo državne imovine (2018) Revidirani strateški plan Ministarstva državne imovine za razdoblje 2019.-2021., dostupno na: https://imovina.gov.hr/UserDocsImages/dokumenti/Izvjesca/Stratesk_plan_MIDIM_2019-2021.pdf
89. Moore, D. R., Cheng, M. I., & Dainty, A. R. (2002). Competence, competency and competencies: performance assessment in organisations. *Work study*, *51*(6), 314-319.
90. Musgrave, P. B., & Musgrave, R. A. (1993). *Javne financije u teoriji i praksi*. Institut za javne financije.
91. Naief, A. (2017). Physical asset management practices in the Saudi public sector. *Built Environment Project and Asset Management*, *7*(1), 19-31.
92. National Research Council. (2004). *Investments in Federal Facilities: Asset Management Strategies for the 21st Century*. National Academies Press.
93. Niven, P. R. (2002). *Balanced scorecard step-by-step: Maximizing performance and maintaining results*. John Wiley & Sons.
94. Nordio, D. (2017). U*pravljanje nekretninama javnog sektora: Diplomski rad* (Doctoral dissertation, University of Split. Faculty of economics Split.).
95. Oberle, A. P. (2004). Understanding public land management through role-playing. *Journal of Geography*, *103*(5), 199-210.

96. Ong, R., Phelps, C., Rowley, S., & Wood, G. A. (2018). Spatial and temporal patterns in housing supply: a descriptive analysis. *Urban Policy and Research*, *36*(3), 287-303.
97. Oreč, M. (2017). *Fiskalni kapacitet vs regionalni potencijal jedinica lokalne i regionalne samouprave*
98. Ott, K., & Bajo, A. (2001). Local government budgeting in Croatia. *Zagreb: Institute of Public Finance*.
99. Ott, K., Bronić, M., Urban, I., Škoc, I., Bađun, M., & Primorac, M. Indeks otvorenosti proračuna 33 hrvatska grada.
100. Pandžić, J. (2014). Prenamjena vojnih nekretnina u Hrvatskoj. *Polemos: časopis za interdisciplinarna istraživanja rata i mira*, *17*(33-34), 194-196.
101. Petak, Z. (2002, September). Decentralisation of government finance in transition countries, The case study of Croatia. In *Workshop in Political Theory and Policy Analysis, Colloquium series*.
102. Pezo, H. (2017). *Planiranje i izvršavanje proračuna kod jedinice lokalne samouprave na primjeru grada Omiša* (Doctoral dissertation, University of Split. Faculty of economics Split.).
103. Pfnür, A. (2005). *Moderni menadžment nekretnina. Facility Management i Corporate Real Estate Management* (No. 42374). Darmstadt Technical University, Department of Business Administration, Economics and Law, Institute for Business Studies (BWL).
104. Phelps, A. (2010). Rationale, practice and outcomes in municipal property asset management. *Journal of Corporate Real Estate*, *12*(3), 157-174.
105. Phelps, A. (2011). Municipal property asset management–a comparative study of UK and Russia. *International Journal of Strategic Property Management*, *15*(4), 416-437.
106. Pollitt, C., & Bouckaert, G. (2004). *Public management reform: A comparative analysis*. Oxford University Press, USA.
107. Pravilnik o financijskom izvještavanju u proračunskom računovodstvu (NN 3/15, 93/15, 135/15, 2/17, 28/17 i 3/18)
108. Pravilnik o proračunskom računovodstvu i Računskom planu (NN 124/14, 115/15 i 87/16)
109. Priest, R. (2006). Integrating property management into overall business and financial planning. *Journal of Retail & Leisure Property*, *5*(3), 235.

110. Rabar, D. (2010). Ocjenjivanje efikasnosti poslovanja hrvatskih bolnica metodom analize omeđivanja podataka. *Ekonomski pregled*, *61*(9-10), 511-533.

111. Rakić, P. (2017). S*trategija upravljanja i raspolaganja nekretninama u vlasništvu Grada Šibenika* (Doctoral dissertation, Polytechnic of Sibenik.).

112. Roje, G. (2011). Ključne postavke i aktivnosti u sustavu upravljanja državnom imovinom. *Zbornik radova s konferencije Hrvatski javni dug: Izazovi razvoja tržišta*, IJF, 237.

113. Rosen, H. S., Ott, K., & Andrijašević, S. (1999). *Javne financije*. Institut za javne financije.

114. Sagalyn, L. B. (2007). Public/private development: Lessons from history, research, and practice. *Journal of the American Planning Association*, *73*(1), 7-22.

115. Sarvan, D. (2004). Pretvorba, raspolaganje i upravljanje nekretninama u vlasništvu jedinica lokalne i područne (regionalne) samouprave. *u: grupa autora:"Upravljanje nekretninama"–"Novi informator", Zagreb*.

116. Savić, G., & Martić, M. (2009). Merenje efikasnosti poslovnih sistema, osnovni modeli i procedura primene DEA. *Ekonomska misao, Beograd*.

117. Schulte, K. W., & Ecke, C. (2006). Public real estate management in Germany: an empirical study. *Managing Government Property Assets: International Experiences." Kaganova, Olga*, 231-254.

118. Sedmihradská, L., Krivorotko, Y., Stoilova, D., Bobcheva, N., Sedmihradska, L., Pollumae, S., ... & Sokrovolska, N. Municipal Asset Management in Central and Eastern Europe: What Can Be Learned from the Case Studies?. *Municipal Asset Management in Transition Countries: Selected Case Studies*, 7.

119. Seršić, V., & Nakić, J. (2013). Upravljanje dobrima u vlasništvu jedinica lokalne samouprave. *Zbornik Pravnog fakulteta Sveučilišta u Rijeci*, *34*(1), 561-586.

120. Sever, I. (1995). *Javne financije: razvoj-osnovne teorije-analiza*. Ekonomski fakultet Rijeka.

121. Seymour-Jones, T. (2017). An Assessment of International Leading Practice in the Integrated Management of Public Sector Property Assets, and its Application to the Australian Public Sector.

122. Simonetti, P. (2010) Vlasništvo i njegove transformacije, jamstvo i zaštita u ustavnom poretku Republike Hrvatske. *Zbornik Pravnog fakulteta u Rijeci* 31(1): 336-364.

123. Simons, R. A. (1994). Public real estate management and the planner's role. *Journal of the American Planning Association*, *60*(3), 333-343.

124. Slijepčević, S. (2009). Mjerenje efikasnosti javne potrošnje u Hrvatskoj. *Efzg, Zagreb*.

125. Slišković, T., & Tica, J. (2016). Prostorna elastičnost traženih cijena stanova na stambenom tržištu grada Zagreba. *Ekonomska misao i praksa*, (1), 23-44.

126. Sopić, M. (2015). *Uloga menadžmenta u upravljanju sportskim objektima grada Čakovca* (Doctoral dissertation, Polytechnic of Međimurje in Čakovec. Management of tourism and sport.).

127. Summerell, R. (2005). Implications of real-property asset management. *The CPA Journal*, *75*(10), 2.

128. Špoljarić, D., & Javorović, I. (2017). Normativna osnova financiranja lokalnih razina vlasti u republici hrvatskoj. *FIP-Financije i pravo*, *5*(1), 61-77.

129. Taitorina, B. A., Zharbolova, A. Z., Zhapakov, S. M., Sadibekova, M., Karasheva, Z. T., & Buribayev, Y. A. (2016). State Property Management in the Republic of Kazakhstan. *Journal of Advanced Research in Law and Economics*, *7*(5 (19)), 1187-1192.

130. Thorncroft, M. (1965). Principles of estate management, *Estates Gazette Limited: London*.

131. Tica, J. (2004). The macroeconomic aspects of the Croatian housing market. *Ekonomski pregled*, *55*(7-8), 641-659.

132. Tica, J. (2011). Ekonomske posljedice politike sprječavanja pada cijene stanova. *EFZG working paper series*, (06), 1-14.

133. Tica, J., & Boras, T. (2012). Uloga tržišta nekretnina i građevinske industrije u strategiji razvoja malog otvorenog gospodarstva. *EFZG Occasional Publications (Department of Macroeconomics)*, *1*, 321-352.

134. Vašiček, D. (2015). State property management in the function of the competitiveness of the Croatian economy. In *Razvoj gospodarske konkurentnosti Republike Hrvatske kao članice EU*. Ekonomski fakultet Sveučilišta u Rijeci.

135. Vašiček, D., & Roje, G. (2017). Public sector property management reform to enhance the economic development: Croatia and Bosnia and Herzegovina current state and international perspectives. In *Journal of Economy and Business,(Special Conference Issue), Faculty of Economics, University of Mostar* (Vol. 1, No. 1, p. 436).

136. Vidakovic, N., Gregurek, M., & Vlahovic, D. (2016). Long Term Effects of Property Tax: Case of Croatia. *Lex Localis, 14*(3), 637.

137. Vitasović, M. (2012). Analiza stanja i doprinosa računovodstvenoga informacijskog sustava i sustava upravljanja financijama u segmentu razvoja proračunskog sustava lokalnih jedinica. *Ekonomska misao i praksa,* (2), 563-594.

138. Vrana, K., Petrović, M. L., Marenjak, S., Ĉengija, J., Breţanski, J., Jug, J., ... & Peroĉević, K. A. (2007). Javno-privatno partnerstvo i drugi načini upravljanja nekretninama u vlasništvu Republike Hrvatske, općina, gradova i ţupanija.

139. Wilson, A. (2013) Asset management – focusing on developing maintenance strategies and improving performance, Conference communication 2013.

140. Wojewnik-Filipkowska, A., Rymarzak, M., & Lausberg, C. (2015). Current managerial topics in public real estate asset management. *Świat Nieruchomości, 94*, 5-10.

141. Wooldridge, J.M. (2010) *Econometric Analysis of Cross Section and Panel Data.* London: The MIT Press.

142. Zakon o cestama (NN 84/11, 22/13, 54/13, 148/13 i 92/14)

143. Zakon o državnoj izmjeri i katastru nekretnina (NN 112/18)

144. Zakon o gradnji (NN 153/13 i 20/17)

145. Zakon o lokalnoj i područnoj (regionalnoj) samoupravi (NN 33/01, 60/01, 129/05, 109/07, 125/08, 36/09, 36/09, 150/11, 144/12, 19/13, 137/15 i 123/17)

146. Zakon o najmu stanova (NN 91/96, 48/98, 66/98, 22/06 i 68/18).

147. Zakon o obveznim odnosima (NN 35/05, 41/08, 125/11, 78/15 i 29/18)

148. Zakon o procjeni vrijednosti nekretnina (NN 78/15)

149. Zakon o proračunu (NN 87/08, 136/12 i 15/15)

150. Zakon o prostornom uređenju (NN 153/13, 65/17 i 114/18)

151. Zakon o trgovačkim društvima (NN 111/93, 34/99, 121/99, 52/00, 118/03, 107/07, 146/08, 137/09, 125/11, 152/11, 111/12, 68/13 i 110/15)

152. Zakon o tržištu kapitala (NN 65/18).

153. Zakon o turističkom i ostalom građevinskom zemljištu neprocijenjenom u postupku pretvorbe i privatizacije (NN 92/10)

154. Zakon o upravljanju državnom imovinom (NN 52/18)

155. Zakon o uređivanju imovinskopravnih odnosa u svrhu izgradnje infrastrukturnih građevina (NN 80/11)

156. Zakon o vlasništvu i drugim stvarnim pravima (NN 91/96, 68/98, 137/99, 22/00, 73/00, 129/00, 114/01, 79/06, 141/06, 146/08, 38/09, 153/09, 143/12 i 152/14)

157. Zakon o vodama (NN 153/09, 63/11, 130/11, 56/13, 14/14 i 46/18)

158. Zakon o zakupu i kupoprodaji poslovnog prostora (NN 125/11, 64/15 i 112/18)

159. Zakon o zemljišnim knjigama (NN 91/96, 68/98, 137/99, 114/01, 100/04, 107/07, 152/08, 126/10, 55/13, 60/13 i 108/17)

160. Zrno, K. (2017). C*ijene nekretnina i poslovni ciklusi: Završni rad* (Doctoral dissertation, University of Split. Faculty of economics Split.).

POPIS GRAFIKONA

Grafikon 2-1 Strateška uloga nekretnina u vlasništvu lokalnih vlasti 34
Grafikon 2-2 Procjena potrebe za vlastitim javnim nekretninama 35
Grafikon 2-3 Broj započetih projekata upravljanja javnim nekretninama u zadnjih 5 godina 36
Grafikon 2-4 Status provedenih projekata 36
Grafikon 2-5 Fokus projekata upravljanja javnim nekretninama u Njemačkoj 37
Grafikon 2-6 Očekivani učinci privatizacije usluga javnih nekretnina u Njemačkoj 38
Grafikon 2-7 Intervencije administracije i političara na proces donošenja odluka vezanih za nekretnine u Njemačkoj 38
Grafikon 2-8 Ključni problemi u upravljanju nekretninama 50
Grafikon 3-1 Vrijednost nekretnina u vlasništvu gradova u RH na dan 31.12.2016. godine u kunama 74
Grafikon 3-2 Relativni udio prvih deset gradova prema vrijednost nekretnina u njihovom vlasništvu na dan 31.12.2016. godine 74
Grafikon 3-3 Vrijednost nekretnina u vlasništvu gradova u 2017. u kunama - posljednjih 10 75
Grafikon 3-4:Relativni udio gradova u ostvarenom ukupnom prihodu od nekretnina u 2017. godini 76
Grafikon 3-5 Vrijednost imovine po stanovniku u 2016. godine u tisućama kuna - prvih 15 gradova 77
Grafikon 3-6 Vrijednost imovine grada per capita u 2016. godini u tisućama kuna - izabrani gradovi 78

POPIS SLIKA

Slika 1.1 Gradovi u Republici Hrvatskoj 11
Slika 1.2 Prikaz velikih gradova (zeleni) u odnosu na ostale gradove 12
Slika 1.3 Prikaz gradova smještenih uz more 13
Slika 1.4 Gradovi županijska središta 14
Slika 2.1 Tijela i uloge u upravljanju državnom imovinom Novog Zelanda 46
Slika 2.2 Model logističke podrške upravljanju nekretninama u vlasništvu gradova 49
Slika 4.1 Javni sektor 108
Slika 4.2 Opća ravnoteža alokacije 113
Slika 4.3 Bergsonovi obrisi blagostanja 115
Slika 4.4 Ilustracija OLS funkcije i COLS granice 128
Slika 4.5 Stohastička funkcija 129
Slika 4.6 Mjerenje učinkovitosti korištenja inputa 130
Slika 4.7 Mjerenje učinkovitosti korištenja outputa 131
Slika 4.8 Grafički prikaz primjera AOMP 134
Slika 4.9 Granica učinkovitosti prema CCR (CRS) i BCC (VRS) modelu 135
Slika 4.10 Primjer određivanja granice učinkovitosti metodom *Free Disposable Hull* 137
Slika 5.1 Konceptualni model istraživanja 146
Slika 5.2 Kretanje pokazatelja nezaposlenosti za razdoblje 2005 – 2016. 155
Slika 5.3 Odnos vrijednosti i prihoda od nekretnina po stanovniku – mali gradovi 163
Slika 5.4 Odnos vrijednosti i prihoda od nekretnina po stanovniku – srednje veliki gradovi 164
Slika 5.5 Odnos vrijednosti i prihoda od nekretnina po stanovniku – veliki gradovi 165
Slika 5.6 DEA modeli i prinosi na opseg 167
Slika 5.7 B-P dijagram – ukupna učinkovitost 176
Slika 5.8 B-P dijagram – usporedba malih gradova na obali i ostalih gradova 178
Slika 5.9 B-P dijagram – usporedba srednje velikih gradova na obali i ostalih gradova 180
Slika 5.10 B-P dijagram – usporedba velikih gradova na obali i ostalih gradova 182
Slika 5.11 B-P dijagram – usporedba velikih gradova koji su sjedišta županija i ostalih gradova 185

POPIS TABLICA

Tablica 1-1 Vrijednost nefinancijske imovine lokalnih jed. 2004. - 2016. (u mlrd. kuna) 4
Tablica 2-1 Kriteriji razlikovanja nekretnina 28
Tablica 2-2 Promjene u imovini tvrtke RKAS 2007. – 2013. 43
Tablica 2-3 Usporedba najčešće korištenih metoda masovne procjene 57
Tablica 3-1: Količina poslovnih prostora, stanova te zemljišta lokalnih jedinica na dan 31.12.2014. prema razinama lokalne vlasti 72
Tablica 4-1 Obilježja javnih i privatnih dobara 111
Tablica 4-2 Prikaz mogućnosti za povećanje učinkovitosti u sektoru obrazovanja 117
Tablica 4-3 Prikaz varijabli za mjerenje učinkovitosti sustava socijalne potrošnje 119
Tablica 4-4 Pregled istraživanja 120
Tablica 4-5 Pregled osnovnih metoda za mjerenje učinkovitosti 123
Tablica 4-6 Primjer AOMP s jednim ulazom i jednim izlazom 132
Tablica 4-7 Rezultati CCR učinkovitosti 133
Tablica 4-8 Primjer izračuna učinkovitosti u modelu jedan input - jedan output 136
Tablica 4-9 Posljedica odabira kamatne stope 142
Tablica 4-10 Usporedba temeljnih karakteristika između metode analize omeđivanja podataka i stohastičke funkcije troška 143
Tablica 5-1 Prosječna vrijednost nekretnina po stanovniku u kunama za radzoblje 2005. – 2016. - deskriptivna statistika 148
Tablica 5-2 Prosječan prihod od nekretnina po stanovniku u kunama za razdoblje 2005. – 20016. - deskriptivna statistika 150
Tablica 5-3 Popis gradova prema veličini 151
Tablica 5-4 Morski gradovi 152
Tablica 5-5 Gradovi sjedišta županija 152
Tablica 5-6 Gradovi koji su implementirali PRLS model upravljanja imovinom 153
Tablica 5-7 Prosječna vrijednost pokazatelj nezaposlenosti stanovništva u gradovima za razdoblje 2005. – 2016. 154
Tablica 5-8 Pokazatelj poduzetničke aktivnosti 155
Tablica 5-9 Fiskalni kapacitet gradova 156
Tablica 5-10 Pokazatelj učinkovitosti upravljanja nekretninama – mali gradovi 172
Tablica 5-11 Pokazatelj učinkovitosti upravljanja nekretninama – srednje veliki gradovi ... 173
Tablica 5-12 Pokazatelj učinkovitosti upravljanja nekretninama – veliki gradovi 174

Tablica 5-13 Rezultati panel-Tobit modela za skupinu malih gradova 179
Tablica 5-14 Rezultati panel-Tobit modela za skupinu srednje velikih gradova..... 181
Tablica 5-15 Rezultati panel-Tobit modela za skupinu velikih gradova 183
Tablica 5-16 Rezultati panel-Tobit modela na uzorku svih gradova – županijskih sjedišta.. 186
Tablica 5-17 Rezultati panel-Tobit modela na uzorku svih gradova – PRLS model..... 188

PRILOZI

Prilog 1 Naziv grada i temeljne informacije i transparentnost

Rbr	Ime grada	Županija	Veličina	Lokacija	Sjedišta županija	PRLS model	Transparentnost		
						Godina uvođenja	2015	2016	2017
1	Bakar	VIII PRIMORSKO-GORANSKA	Mali	More			3	4	5
2	Beli Manastir	XIV OSJEČKO-BARANJSKA	Srednji	Ostali			0	0	1
3	Belišće	XIV OSJEČKO-BARANJSKA	Srednji	Ostali			0	1	3
4	Benkovac	XIII ZADARSKA	Srednji	Ostali			3	2	4
5	Biograd na Moru	XIII ZADARSKA	Mali	More			2	2	2
6	Bjelovar	VII BJELOVARSKO-BILOGORSKA	Veliki	Ostali	Sjedište		4	5	5
7	Buje	XVIII ISTARSKA	Mali	Ostali			4	4	5
8	Buzet	XVIII ISTARSKA	Mali	Ostali			5	5	5
9	Cres	VIII PRIMORSKO-GORANSKA	Mali	More			4	5	5
10	Crikvenica	VIII PRIMORSKO-GORANSKA	Srednji	More		2009	5	5	5
11	Čabar	VIII PRIMORSKO-GORANSKA	Mali	Ostali			3	1	3
12	Čakovec	XX MEĐIMURSKA	Veliki	Ostali	Sjedište		5	4	4
13	Čazma	VII BJELOVARSKO-BILOGORSKA	Mali	Ostali			3	1	2
14	Daruvar	VII BJELOVARSKO-BILOGORSKA	Srednji	Ostali			3	3	4
15	Delnice	VIII PRIMORSKO-GORANSKA	Mali	Ostali			3	4	5
16	Donja Stubica	II KRAPINSKO-ZAGORSKA	Mali	Ostali			3	3	3
17	Donji Miholjac	XIV OSJEČKO-BARANJSKA	Mali	Ostali			3	3	2
18	Drniš	XV ŠIBENSKO-KNINSKA	Mali	Ostali			4	4	4
19	Dubrovnik	XIX DUBROVAČKO-NERETVANSKA	Veliki	More	Sjedište		5	4	5
20	Duga Resa	IV KARLOVAČKA	Srednji	Ostali			4	5	5

21	Dugo Selo	I ZAGREBAČKA	Srednji	Ostali			3	3	2
22	Đakovo	XIV OSJEČKO-BARANJSKA	Srednji	Ostali			1	1	4
23	Đurđevac	VI KOPRIVNIČKO-KRIŽEVAČKA	Mali	Ostali		2016	0	3	3
24	Garešnica	VII BJELOVARSKO-BILOGORSKA	Srednji	Ostali			1	4	4
25	Glina	III SISAČKO-MOSLAVAČKA	Mali	Ostali		2017	4	4	4
26	Gospić	IX LIČKO-SENJSKA	Veliki	Ostali	Sjedište	2016	0	1	0
27	Grubišno Polje	VII BJELOVARSKO-BILOGORSKA	Mali	Ostali			1	2	4
28	Hrvatska Kostajnica	III SISAČKO-MOSLAVAČKA	Mali	Ostali			3	4	4
29	Hvar	XVII SPLITSKO-DALMATINSKA	Mali	More			3	4	4
30	Ilok	XVI VUKOVARSKO-SRIJEMSKA	Mali	Ostali			2	0	4
31	Imotski	XVII SPLITSKO-DALMATINSKA	Srednji	Ostali			1	0	0
32	Ivanec	V VARAŽDINSKA	Srednji	Ostali			3	5	5
33	Ivanić-Grad	I ZAGREBAČKA	Srednji	Ostali			4	4	4
34	Jastrebarsko	I ZAGREBAČKA	Srednji	Ostali			4	4	4
35	Karlovac	IV KARLOVAČKA	Veliki	Ostali	Sjedište	2007	4	5	4
36	Kastav	VIII PRIMORSKO-GORANSKA	Srednji	Ostali			3	5	5
37	Kaštela	XVII SPLITSKO-DALMATINSKA	Veliki	More	Sjedište		4	4	4
38	Klanjec	II KRAPINSKO-ZAGORSKA	Mali	Ostali			1	4	5
39	Knin	XV ŠIBENSKO-KNINSKA	Srednji	Ostali		2012	1	1	4
40	Komiža	XVII SPLITSKO-DALMATINSKA	Mali	Ostali			3	3	3
41	Koprivnica	VI KOPRIVNIČKO-KRIŽEVAČKA	Veliki	Ostali	Sjedište		5	5	5
42	Korčula	XIX DUBROVAČKO-NERETVANSKA	Mali	More			3	4	4
43	Kraljevica	VIII PRIMORSKO-GORANSKA	Mali	More			4	2	4
44	Krapina	II KRAPINSKO-ZAGORSKA	Veliki	Ostali	Sjedište		4	3	5
45	Križevci	VI KOPRIVNIČKO-KRIŽEVAČKA	Srednji	Ostali			2	4	2
46	Krk	VIII PRIMORSKO-GORANSKA	Mali	More		2011	4	4	4
47	Kutina	III SISAČKO-MOSLAVAČKA	Srednji	Ostali			2	3	4

48	Labin	XVIII ISTARSKA	Srednji	More		2009	4	5	4
49	Lepoglava	V VARAŽDINSKA	Mali	Ostali			4	4	5
50	Lipik	XI POŽEŠKO-SLAVONSKA	Mali	Ostali			4	4	4
51	Ludbreg	V VARAŽDINSKA	Mali	Ostali			4	2	5
52	Makarska	XVII SPLITSKO-DALMATINSKA	Srednji	More			3	4	4
53	Mali Lošinj	VIII PRIMORSKO-GORANSKA	Mali	More			3	5	4
54	Metković	XIX DUBROVAČKO-NERETVANSKA	Srednji	Ostali			2	3	3
55	Mursko Središće	XX MEĐIMURSKA	Mali	Ostali			1	2	2
56	Našice	XIV OSJEČKO-BARANJSKA	Srednji	Ostali		2017	4	1	3
57	Nin	XIII ZADARSKA	Mali	More			0	0	3
58	Nova Gradiška	XII BRODSKO-POSAVSKA	Srednji	Ostali		2010	0	2	4
59	Novalja	IX LIČKO-SENJSKA	Mali	More		2017	3	2	3
60	Novi Marof	V VARAŽDINSKA	Srednji	Ostali			2	2	3
61	Novi Vinodolski	VIII PRIMORSKO-GORANSKA	Mali	More			3	3	2
62	Novigrad-Cittanova	XVIII ISTARSKA	Mali	More			4	4	4
63	Novska	III SISAČKO-MOSLAVAČKA	Srednji	Ostali			4	3	5
64	Obrovac	XIII ZADARSKA	Mali	Ostali			1	1	4
65	Ogulin	IV KARLOVAČKA	Srednji	Ostali			4	4	4
66	Omiš	XVII SPLITSKO-DALMATINSKA	Srednji	More			4	3	3
67	Opatija	VIII PRIMORSKO-GORANSKA	Srednji	More		2013	5	5	5
68	Opuzen	XIX DUBROVAČKO-NERETVANSKA	Mali	More			2	3	3
69	Orahovica	X VIROVITIČKO-PODRAVSKA	Mali	Ostali			3	4	3
70	Oroslavje	II KRAPINSKO-ZAGORSKA	Mali	Ostali			2	1	5
71	Osijek	XIV OSJEČKO-BARANJSKA	Veliki	Ostali	Sjedište	2007	5	5	5
72	Otočac	IX LIČKO-SENJSKA	Mali	Ostali		2016	0	2	3
73	Otok	XVI VUKOVARSKO-SRIJEMSKA	Mali	Ostali			0	1	1
74	Ozalj	IV KARLOVAČKA	Mali	Ostali			3	5	5
75	Pag	XIII ZADARSKA	Mali	More			0	1	3

76	Pakrac	XI POŽEŠKO-SLAVONSKA	Mali	Ostali			3	3	3
77	Pazin	XVIII ISTARSKA	Veliki	Ostali	Sjedište		5	5	5
78	Petrinja	III SISAČKO-MOSLAVAČKA	Srednji	Ostali			0	3	1
79	Pleternica	XI POŽEŠKO-SLAVONSKA	Srednji	Ostali			0	0	1
80	Ploče	XIX DUBROVAČKO-NERETVANSKA	Srednji	More			3	2	3
81	Poreč	XVIII ISTARSKA	Srednji	More			4	5	5
82	Požega	XI POŽEŠKO-SLAVONSKA	Veliki	Ostali	Sjedište		1	3	2
83	Pregrada	II KRAPINSKO-ZAGORSKA	Mali	Ostali			4	4	5
84	Prelog	XX MEĐIMURSKA	Mali	Ostali			4	3	5
85	Pula	XVIII ISTARSKA	Veliki	More		2015	5	5	5
86	Rab	VIII PRIMORSKO-GORANSKA	Mali	More		2012	1	4	5
87	Rijeka	VIII PRIMORSKO-GORANSKA	Veliki	More	Sjedište		5	5	5
88	Rovinj	XVIII ISTARSKA	Srednji	More			1	2	5
89	Samobor	I ZAGREBAČKA	Veliki	Ostali			2	3	5
90	Senj	IX LIČKO-SENJSKA	Mali	More			3	3	1
91	Sinj	XVII SPLITSKO-DALMATINSKA	Srednji	Ostali			1	1	4
92	Sisak	III SISAČKO-MOSLAVAČKA	Veliki	Ostali	Sjedište	2016	0	4	3
93	Skradin	XV ŠIBENSKO-KNINSKA	Mali	More			1	1	3
94	Slatina	X VIROVITIČKO-PODRAVSKA	Srednji	Ostali		2017	3	3	4
95	Slavonski Brod	XII BRODSKO-POSAVSKA	Veliki	Ostali	Sjedište		5	5	5
96	Slunj	IV KARLOVAČKA	Mali	Ostali			4	4	4
97	Solin	XVII SPLITSKO-DALMATINSKA	Srednji	Ostali			3	3	4
98	Split	XVII SPLITSKO-DALMATINSKA	Veliki	More	Sjedište		5	5	4
99	Stari Grad	XVII SPLITSKO-DALMATINSKA	Mali	More			0	2	3
100	Supetar	XVII SPLITSKO-DALMATINSKA	Mali	More		2015	1	3	3
101	Sveta Nedelja	I ZAGREBAČKA	Srednji	Ostali			4	4	4
102	Sveti Ivan Zelina	I ZAGREBAČKA	Srednji	Ostali			0	0	4
103	Šibenik	XV ŠIBENSKO-KNINSKA	Veliki	More	Sjedište		5	5	5

104	Trilj	XVII SPLITSKO-DALMATINSKA	Mali	Ostali			0	1	2
105	Trogir	XVII SPLITSKO-DALMATINSKA	Srednji	More			3	4	4
106	Umag	XVIII ISTARSKA	Srednji	More		2010	4	3	4
107	Valpovo	XIV OSJEČKO-BARANJSKA	Srednji	Ostali			2	1	0
108	Varaždin	V VARAŽDINSKA	Veliki	Ostali	Sjedište		4	4	3
109	Varaždinske Toplice	V VARAŽDINSKA	Mali	Ostali			3	3	4
110	Velika Gorica	I ZAGREBAČKA	Veliki	Ostali			4	4	4
111	Vinkovci	XVI VUKOVARSKO-SRIJEMSKA	Veliki	Ostali			0	0	4
112	Virovitica	X VIROVITIČKO-PODRAVSKA	Veliki	Ostali	Sjedište	2015	3	4	4
113	Vis	XVII SPLITSKO-DALMATINSKA	Mali	More			2	1	3
114	Vodice	XV ŠIBENSKO-KNINSKA	Mali	More		2017	5	5	5
115	Vodnjan	XVIII ISTARSKA	Mali	Ostali			1	1	1
116	Vrbovec	I ZAGREBAČKA	Srednji	Ostali			3	3	4
117	Vrbovsko	VIII PRIMORSKO-GORANSKA	Mali	Ostali			1	3	5
118	Vrgorac	XVII SPLITSKO-DALMATINSKA	Mali	Ostali			0	0	0
119	Vrlika	XVII SPLITSKO-DALMATINSKA	Mali	Ostali			1	1	3
120	Vukovar	XVI VUKOVARSKO-SRIJEMSKA	Veliki	Ostali	Sjedište		4	4	4
121	Zabok	II KRAPINSKO-ZAGORSKA	Mali	Ostali		2012	2	3	5
122	Zadar	XIII ZADARSKA	Veliki	More	Sjedište		4	5	5
123	Zagreb	XXI GRAD ZAGREB	Veliki	Ostali	Sjedište		5	5	5
124	Zaprešić	I ZAGREBAČKA	Srednji	Ostali			4	4	4

Izvor: 1) Veličina grada, Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, NN 33/01, 60/01, 129/05, 109/07, 125/08, 36/09, 36/09, 150/11, 144/12, 19/13, 137/15, 123/17; 2) Gradovii sjedišta županija, Zakon o područjima županija, gradova i općina u Republici Hrvatskoj, NN: 86/06, 125/06, 16/07, 95/08, 46/10, 145/10, 37/13, 44/13, 45/13, 110/15; 3) Lokacija gradova, Državna geodetska uprava; 4) Transparentnost gradova, Institut za javne financije; 5) PRLS model, Libusoft Cicom d.o.o.

Prilog 2 Broj stanovnika u gradovima

Rbr	Ime grada	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016
1	Bakar	7783	7864	7966	8037	8115	8209	8274	8321	8278	8268	8264	8231	8173
2	Beli Manastir	10738	10652	10560	10453	10362	10228	10109	9971	9853	9634	9439	9231	8970
3	Belišće	11245	11220	11161	11107	11017	10948	10851	10773	10643	10538	10488	10333	10150
4	Benkovac	9856	10055	10301	10543	10854	10964	11021	11037	10914	10805	10550	10177	9879
5	Biograd na Moru	4993	5139	5247	5363	5403	5463	5555	5609	5688	5763	5746	5739	5731
6	Bjelovar	41052	40917	40842	40802	40653	40536	40317	40053	39878	39694	39551	39180	38783
7	Buje	5049	5117	5121	5158	5208	5201	5190	5183	5111	5136	5120	5105	5039
8	Buzet	6101	6138	6129	6161	6170	6179	6131	6140	6122	6107	6092	6055	6057
9	Cres	2830	2854	2871	2879	2851	2864	2877	2901	2915	2953	2956	2937	2903
10	Crikvenica	10414	10582	10792	10993	11040	11037	11130	11127	11157	11160	11234	11067	10905
11	Čabar	4036	4019	3944	3873	3857	3831	3789	3734	3675	3644	3581	3498	3388
12	Čakovec	26927	27002	26936	26960	27002	27044	27078	27114	27095	27793	27852	27868	27801
13	Čazma	8432	8338	8332	8236	8239	8205	8096	8013	7940	7825	7744	7655	7545
14	Daruvar	12357	12250	12106	11955	11848	11777	11662	11568	11515	11430	11280	11041	10839
15	Delnice	6143	6151	6059	6029	6002	5983	5958	5909	5883	5823	5776	5693	5586
16	Donja Stubica	5496	5687	5692	5500	5527	5654	5683	5669	5669	5688	5752	5842	5809
17	Donji Miholjac	9920	9861	9785	9724	9617	9576	9504	9437	9352	9288	9186	9054	8910
18	Drniš	7993	7916	7881	7794	7736	7661	7539	7393	7255	7102	6989	6804	6616
19	Dubrovnik	42171	42240	42372	42351	42612	42654	42614	42647	42794	43053	43400	43697	43950
20	Duga Resa	11658	11591	11552	11497	11377	11267	11209	11128	11079	11015	10940	10843	10776
21	Dugo Selo	14922	15384	15738	16159	16556	16958	17343	17810	18213	18332	18323	18240	18143
22	Đakovo	28083	28088	28000	27936	27936	27855	27792	27721	27659	27551	27238	26865	26433
23	Đurđevac	8549	8549	8518	8445	8389	8353	8301	8244	8202	8160	8088	8020	7903
24	Garešnica	11011	10953	10812	10706	10664	10610	10510	10362	10196	10050	9865	9649	9449
25	Glina	11099	10825	10608	10500	10195	9739	9387	8972	8656	8341	7989	7694	7408
26	Gospić	13669	13599	13435	13270	13050	12909	12767	12584	12425	12381	12280	12186	12067

27	Grubišno Polje	7132	7049	6937	6791	6744	6629	6521	6409	6309	6185	6070	5917	5745
28	Hrvatska Kostajnica	3235	3212	3167	3052	2954	2897	2795	2686	2596	2488	2405	2312	2197
29	Hvar	3995	4063	4142	4228	4257	4242	4247	4303	4330	4388	4410	4440	4468
30	Ilok	7573	7422	7287	7157	7076	6907	6805	6652	6580	6437	6351	6209	6030
31	Imotski	10447	10597	10657	10709	10742	10760	10757	10716	10584	10534	10525	10587	10298
32	Ivanec	14021	14030	14002	13969	13915	13862	13765	13710	13689	13597	13519	13392	13326
33	Ivanić-Grad	14457	14484	14455	14479	14505	14557	14560	14518	14439	14363	14265	14065	13858
34	Jastrebarsko	15900	15911	15906	15934	15952	15921	15873	15851	15771	15686	15583	15431	15293
35	Karlovac	58203	57978	57513	56969	56616	56156	55812	55265	54822	54328	53770	53134	52488
36	Kastav	9331	9611	9846	10137	10307	10315	10422	10547	10637	10703	10688	10705	10666
37	Kaštela	34139	34968	35914	36813	37540	38045	38521	39070	39656	40217	40501	40586	40658
38	Klanjec	3071	3023	3013	2995	2986	2959	2918	2889	2870	2832	2800	2765	2738
39	Knin	16352	16465	16569	16491	16371	16010	15491	14924	14330	13858	13525	13095	12594
40	Komiža	1513	1495	1499	1502	1499	1531	1524	1534	1521	1542	1556	1524	1500
41	Koprivnica	30457	30520	30614	30663	30784	30789	30835	30926	31004	31021	31012	30864	30466
42	Korčula	5645	5642	5665	5665	5659	5666	5662	5621	5632	5631	5606	5591	5550
43	Kraljevica	4481	4562	4592	4635	4665	4643	4621	4619	4588	4604	4566	4520	4485
44	Krapina	12815	12779	12727	12657	12611	12544	12484	12465	12402	12390	12350	12243	12132
45	Križevci	21416	21421	21322	21298	21303	21249	21177	21083	21042	20959	20778	20602	20303
46	Krk	5719	5830	5941	5999	6105	6190	6269	6346	6454	6527	6644	6675	6748
47	Kutina	23517	23452	23330	23205	23039	22929	22818	22683	22611	22391	22164	21796	21427
48	Labin	11956	11916	11872	11830	11806	11766	11664	11566	11464	11411	11290	11178	11057
49	Lepoglava	8570	8530	8488	8454	8406	8341	8297	8227	8158	8097	7989	7909	7785
50	Lipik	6590	6538	6489	6478	6409	6316	6192	6026	5823	5763	5639	5564	5496
51	Ludbreg	8323	8399	8418	8420	8440	8480	8499	8472	8497	9176	9094	8953	8801
52	Makarska	12168	12694	13062	13313	13634	13830	13836	13879	13909	14151	14217	14217	14317
53	Mali Lošinj	8007	8003	8030	8072	8074	8111	8127	8144	8151	8175	8175	8147	8115
54	Metković	15635	15856	16031	16247	16457	16716	16794	16762	16737	16665	16743	16619	16371
55	Mursko Središće	6324	6320	6368	6361	6366	6356	6321	6289	6305	6283	6230	6215	6193

56	Našice	16515	16540	16491	16443	16361	16313	16253	16264	16203	16187	16212	16016	15798
57	Nin	2440	2526	2602	2662	2720	2741	2749	2755	2820	2850	2854	2876	2908
58	Nova Gradiška	14707	14726	14639	14585	14474	14393	14263	14151	14070	13906	13653	13452	13133
59	Novalja	3289	3380	3460	3529	3595	3636	3671	3739	3788	3929	3942	3932	3961
60	Novi Marof	13465	13433	13413	13441	13330	13314	13252	13185	13115	13104	12973	12802	12618
61	Novi Vinodolski	4979	5025	5090	5126	5131	5146	5119	5133	5117	5104	5090	4983	4925
62	Novigrad-Cittanova	3885	3980	4116	4198	4275	4318	4351	4372	4342	4365	4402	4450	4481
63	Novska	13940	13927	13910	13837	13803	13679	13569	13467	13292	13094	12973	12738	12453
64	Obrovac	3614	3847	4086	4221	4283	4315	4328	4306	4289	4264	3980	3844	3778
65	Ogulin	14579	14481	14450	14338	14233	14095	13949	13852	13741	13674	13571	13379	13182
66	Omiš	14853	14963	15033	15055	15025	14952	14943	14863	14874	14930	14903	14798	14815
67	Opatija	12102	12037	11939	11798	11699	11740	11677	11645	11577	11514	11449	11305	11145
68	Opuzen	3346	3352	3344	3335	3292	3296	3260	3257	3265	3212	3176	3186	3164
69	Orahovica	5476	5445	5434	5402	5405	5380	5304	5272	5195	5160	5072	4962	4844
70	Oroslavje	6113	6149	6124	6162	6166	6143	6134	6134	6121	6116	6118	6108	6074
71	Osijek	111795	111216	110274	109152	108749	108473	108054	107832	107495	107187	106610	105921	104638
72	Otočac	10465	10343	10219	10153	10048	9874	9792	9674	9575	9448	9384	9238	9144
73	Otok	6760	6683	6592	6521	6490	6425	6353	6308	6252	6205	6014	5836	5633
74	Ozalj	7242	7166	7092	7042	6986	6913	6843	6760	6702	6646	6570	6457	6316
75	Pag	3891	3918	3930	3925	3893	3884	3861	3829	3824	3809	3745	3722	3700
76	Pakrac	9055	9008	8967	8859	8783	8609	8488	8296	7960	7838	7720	7462	7263
77	Pazin	8913	8854	8836	8770	8722	8724	8645	8617	8547	8494	8502	8442	8383
78	Petrinja	25164	25162	25205	25256	25241	25027	24766	24366	24014	23584	23236	22801	22128
79	Pleternica	12095	12011	11889	11771	11687	11553	11369	11221	11108	11002	10906	10662	10284
80	Ploče	10426	10390	10401	10381	10343	10281	10157	10052	9914	9672	9514	9415	9141
81	Poreč	15838	16038	16186	16422	16525	16597	16713	16763	16819	16884	16937	17000	17127
82	Požega	27219	27102	26956	26850	26666	26445	26308	26107	25927	25744	25455	24978	24522
83	Pregrada	6848	6786	6757	6713	6674	6654	6598	6553	6517	6450	6378	6287	6226
84	Prelog	7883	7929	7877	7857	7823	7842	7827	7788	7800	7768	7740	7690	7671

85	Pula	57547	57660	58078	58101	58145	57960	57640	57138	56872	56673	56676	56540	56527
86	Rab	7883	7949	8008	8035	8050	8033	8061	8108	8115	8162	8152	8117	8027
87	Rijeka	137847	136508	135155	133449	131733	130310	129042	127760	126410	125023	123725	121975	120855
88	Rovinj	14136	14160	14208	14266	14250	14307	14293	14321	14331	14387	14441	14417	14451
89	Samobor	36364	36570	36788	37007	37217	37427	37638	37770	37804	37825	37801	37728	37598
90	Senj	7573	7560	7516	7411	7322	7237	7173	7110	7048	6978	6856	6685	6561
91	Sinj	24240	24308	24421	24475	24613	24703	24797	24828	24815	24751	24742	24617	24476
92	Sisak	51483	51074	50407	49684	49012	48398	47880	47407	46898	46321	45844	45081	44411
93	Skradin	3973	3971	3964	3960	3923	3884	3844	3763	3690	3609	3549	3451	3348
94	Slatina	14416	14313	14222	14123	14002	13857	13727	13599	13466	13345	13181	12904	12697
95	Slavonski Brod	60544	60545	60371	60238	60129	59398	59208	59002	58720	58330	57797	56769	55825
96	Slunj	5899	5759	5670	5584	5534	5211	5110	4963	4832	4752	4592	4476	4361
97	Solin	20679	21373	22011	22582	23165	23432	23861	24261	24509	24994	25349	25564	25892
98	Split	185157	184393	182898	181754	180102	179423	178347	177624	176826	175537	174333	173109	172362
99	Stari Grad	2614	2661	2682	2722	2750	2757	2776	2779	2828	2842	2848	2867	2866
100	Supetar	3615	3713	3799	3849	3944	3994	4055	4135	4198	4260	4326	4362	4382
101	Sveta Nedelja	15746	16156	16737	17195	17570	17888	18050	18136	18251	18315	18334	18292	18298
102	Sveti Ivan Zelina	15963	16007	16024	16019	16063	16084	15979	15884	15822	15794	15642	15377	15190
103	Šibenik	47417	47256	47082	46936	46834	46648	46384	46191	45970	45845	45714	45294	45008
104	Trilj	9235	9179	9180	9170	9155	9115	9087	9042	8949	8852	8713	8621	8540
105	Trogir	12575	12742	12994	13106	13199	13207	13219	13194	13232	13202	13229	13223	13142
106	Umag	12720	12851	13031	13183	13282	13450	13481	13444	13493	13530	13692	13773	13828
107	Valpovo	11778	11707	11662	11651	11674	11650	11585	11482	11456	11386	11262	11095	10937
108	Varaždin	47185	47050	46972	46968	46912	46902	46957	46938	46781	46574	46476	46319	46294
109	Varaždinske Toplice	6717	6725	6648	6551	6476	6429	6354	6370	6388	6339	6237	6120	6020
110	Velika Gorica	62297	62594	62733	62899	63162	63345	63500	63595	63721	63941	63984	63651	63323
111	Vinkovci	35073	35148	35147	35201	35212	35214	35285	35275	35354	35519	35470	35288	34986
112	Virovitica	21691	21617	21547	21524	21384	21351	21313	21256	21231	21206	21160	20893	20556
113	Vis	1768	1796	1849	1876	1893	1896	1926	1935	1983	2010	2032	2035	2028

114	Vodice	7074	7414	7784	8104	8511	8706	8846	8969	9050	9180	9321	9327	9289
115	Vodnjan	5620	5702	5829	5925	6048	6133	6138	6140	6190	6237	6218	6237	6353
116	Vrbovec	14615	14630	14649	14667	14743	14789	14813	14844	14804	14734	14685	14523	14341
117	Vrbovsko	5573	5491	5400	5327	5262	5181	5090	5003	4900	4796	4714	4578	4441
118	Vrgorac	6589	6619	6718	6765	6784	6780	6653	6486	6350	6166	6040	5911	5754
119	Vrlika	2536	2491	2448	2395	2343	2262	2198	2103	2024	1938	1864	1930	1879
120	Vukovar	29441	29073	28937	28658	28515	28112	27764	27533	27179	26425	25511	24938	24219
121	Zabok	9069	9085	9062	9041	9043	9020	8986	8993	8985	8988	8963	8881	8840
122	Zadar	73284	73569	74006	74336	74538	74673	75017	75298	75416	75575	75537	75346	75437
123	Zagreb	776540	777216	779521	782128	784532	787448	789655	791883	794101	796866	799999	801349	803647
124	Zaprešić	23196	23656	24340	24744	24887	25097	25227	25248	25376	25328	25380	25319	25181
125	Zlatar	6334	6315	6286	6268	6202	6141	6089	6084	6054	6001	5969	5855	5738
126	Županja	11960	12033	12212	12470	12619	12579	12169	11973	11892	11788	11579	11196	10644

Izvor: Broj stanovnika prema DZS. Procjena stanovništva po gradovima na 31.12.2018

Prilog 3 Fiskalni kapacitet gradova

Rbr	Ime grada	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016
1	Bakar	3.710,25	3.674,60	6.620,56	5.730,60	6.698,51	5.627,34	6.321,04	5.792,51	26.393,22	4.763,64	5.745,55	6.614,86	5.408,03
2	Beli Manastir	2.472,52	2.723,86	3.084,12	3.519,45	4.103,55	3.448,23	2.883,32	3.139,89	2.979,04	3.055,62	3.588,35	3.830,45	4.348,18
3	Belišće	1.023,88	1.288,41	1.345,87	1.876,43	4.975,88	1.769,33	1.641,59	1.842,68	2.280,11	1.980,58	2.911,48	2.965,85	2.902,32
4	Benkovac	2.202,77	2.562,74	2.522,38	3.333,97	3.444,32	2.884,30	2.711,94	2.286,54	2.726,40	2.199,88	2.377,21	2.340,68	2.627,82
5	Biograd na Moru	3.751,27	4.446,25	4.208,14	4.599,51	5.359,89	6.551,59	7.963,16	5.816,24	5.664,20	5.609,10	5.631,49	5.913,20	6.901,60
6	Bjelovar	2.035,42	2.020,98	2.307,41	2.780,92	3.082,09	3.003,75	2.588,08	2.640,19	2.617,44	2.805,04	2.702,17	2.709,17	2.934,41
7	Buje	2.499,00	2.553,99	2.875,26	3.595,28	4.061,17	3.885,40	4.344,60	3.636,84	3.346,90	3.851,53	3.286,14	3.817,14	4.422,38
8	Buzet	5.413,60	5.560,51	6.232,45	7.636,41	7.760,59	6.744,75	6.496,80	6.150,11	6.876,62	6.512,57	6.284,92	5.877,21	4.692,82
9	Cres	6.830,65	7.530,42	5.745,31	6.698,26	5.886,81	6.868,21	6.066,33	6.154,87	6.473,11	7.059,00	7.298,54	7.551,45	8.093,46
10	Crikvenica	4.814,74	5.373,01	5.485,70	5.358,92	6.375,54	5.888,93	5.479,12	5.867,79	6.951,53	6.233,34	6.826,86	6.747,94	7.549,82
11	Čabar	3.077,60	2.496,96	2.961,50	4.544,26	4.219,00	3.333,06	3.527,49	3.285,83	3.490,53	3.220,72	3.764,01	3.925,59	3.322,07
12	Čakovec	2.341,59	2.581,74	3.175,15	3.457,50	3.656,31	3.478,21	3.443,07	3.199,37	3.269,06	3.344,34	3.519,25	3.512,70	3.783,24
13	Čazma	894,66	1.277,52	1.438,84	2.022,46	2.116,50	2.032,37	1.929,53	1.862,90	1.902,74	1.932,01	2.033,06	2.561,85	3.012,36
14	Daruvar	1.690,53	1.946,03	2.484,71	3.087,30	3.060,82	2.434,51	2.363,96	2.181,38	2.169,16	2.420,31	2.320,00	2.222,77	2.291,08
15	Delnice	3.387,61	3.901,46	4.943,93	5.975,28	6.171,87	6.150,36	5.187,98	4.928,07	4.892,02	4.771,78	5.016,58	4.368,43	3.878,77
16	Donja Stubica	1.160,19	1.073,09	1.577,00	1.962,35	2.229,83	2.105,91	1.688,50	1.966,65	3.179,79	1.818,92	1.637,24	1.792,17	2.499,43
17	Donji Miholjac	1.182,38	1.599,67	1.398,44	1.565,88	1.741,63	2.085,25	2.511,57	1.517,72	2.015,68	2.064,78	1.804,80	1.486,91	1.659,03
18	Drniš	2.038,19	2.256,27	2.531,03	3.574,91	3.648,76	2.928,86	2.578,48	2.864,59	2.975,68	2.982,36	3.194,05	3.784,57	3.970,57
19	Dubrovnik	4.175,06	5.297,96	6.361,57	7.741,92	7.677,15	6.581,07	6.325,24	6.488,23	7.323,95	7.758,77	8.360,83	8.486,23	8.773,10
20	Duga Resa	1.110,60	1.032,66	1.268,63	1.842,44	2.214,31	2.176,92	2.358,43	1.874,33	2.090,13	2.101,02	1.970,50	1.778,38	1.987,46
21	Dugo Selo	1.791,75	1.982,40	2.118,94	2.904,47	3.866,79	2.916,29	2.215,24	2.255,06	1.990,85	2.166,28	2.276,87	2.113,95	2.345,50
22	Đakovo	961,84	833,74	1.104,83	1.445,62	1.451,77	1.538,91	1.422,47	1.204,13	1.297,67	1.311,20	1.445,63	1.859,76	2.231,34
23	Đurđevac	1.639,14	2.099,92	2.000,52	2.589,42	2.841,81	2.564,11	2.544,22	2.367,37	2.451,37	2.989,91	3.356,17	3.859,94	4.096,44
24	Garešnica	1.190,74	1.158,15	1.249,25	1.751,04	1.762,64	1.676,80	1.544,68	1.517,38	1.516,43	1.554,34	1.874,51	2.230,77	2.413,09
25	Glina	1.422,24	1.325,22	1.413,83	1.918,13	2.252,65	2.367,65	2.181,56	2.062,64	2.642,74	2.629,63	2.902,90	2.900,53	4.448,96
26	Gospić	3.175,75	3.099,79	5.689,45	5.037,04	4.041,94	4.001,25	4.673,31	3.971,44	4.646,78	4.946,35	5.495,75	4.661,58	4.477,78

27	Grubišno Polje	1.282,35	1.261,97	1.541,23	2.386,94	3.098,38	2.732,83	2.399,35	3.047,76	2.755,19	2.729,58	2.505,51	2.796,66	4.000,55
28	Hrvatska Kostajnica	2.569,83	2.371,22	2.039,34	3.146,22	2.424,01	2.871,43	2.345,26	5.623,32	2.417,68	2.118,46	2.819,63	4.181,68	3.979,23
29	Hvar	3.773,56	5.259,19	6.650,24	8.028,23	7.992,00	6.685,40	6.285,82	5.856,64	5.664,98	6.917,49	7.673,80	7.488,14	8.701,54
30	Ilok	1.791,52	1.770,34	1.767,55	2.299,64	2.591,16	2.302,92	2.481,98	2.078,56	2.023,86	1.992,08	2.679,25	2.096,91	2.436,20
31	Imotski	2.308,10	2.872,93	2.846,46	3.680,51	5.980,34	5.650,33	3.422,08	3.205,19	3.041,30	3.206,45	2.626,38	2.456,45	2.651,70
32	Ivanec	942,74	921,65	1.225,24	1.716,51	2.048,57	1.913,33	2.006,13	1.636,73	1.737,99	2.098,39	1.827,41	1.748,68	1.949,15
33	Ivanić-Grad	1.992,00	2.311,13	2.854,64	3.182,55	4.102,20	3.479,81	3.538,68	3.092,99	3.423,67	3.284,05	3.343,55	3.357,76	3.466,74
34	Jastrebarsko	2.648,71	1.804,41	2.457,42	2.924,24	2.938,59	3.044,77	2.496,06	3.010,56	2.762,68	4.183,53	2.868,37	3.064,63	3.128,95
35	Karlovac	2.240,21	2.422,40	2.577,43	3.155,15	3.603,43	3.527,89	3.334,72	3.178,45	3.328,56	3.843,69	3.816,29	3.590,00	4.363,72
36	Kastav	2.133,31	2.218,38	2.714,33	3.550,92	3.379,63	3.701,73	3.060,47	2.751,49	2.768,29	3.408,31	2.856,38	3.438,14	4.091,35
37	Kaštela	2.048,46	1.995,51	2.348,34	2.654,36	3.002,59	2.590,01	2.263,51	2.516,76	2.350,36	2.826,90	2.393,65	2.592,32	2.969,32
38	Klanjec	1.241,69	2.105,65	2.206,59	2.614,15	2.400,88	2.620,21	2.123,04	2.057,21	2.500,18	2.444,99	2.586,61	2.049,50	2.086,53
39	Knin	1.474,82	1.629,54	1.489,70	1.955,75	2.002,48	2.864,75	3.262,41	2.724,05	2.154,75	2.165,70	2.639,38	2.600,35	3.193,83
40	Komiža	2.585,49	3.662,02	3.464,29	5.114,92	5.217,07	5.322,72	4.400,23	4.088,34	4.550,35	5.461,13	4.507,86	6.603,47	3.984,99
41	Koprivnica	2.810,68	3.212,04	3.992,36	4.153,23	5.002,66	4.393,73	4.145,65	3.746,62	3.786,99	3.708,24	3.750,16	4.025,00	3.789,10
42	Korčula	2.938,89	2.477,04	2.738,15	3.394,23	3.680,08	3.077,45	4.034,07	5.433,06	4.729,59	3.863,51	5.398,68	3.434,04	4.225,83
43	Kraljevica	2.035,26	2.407,35	3.085,53	4.568,72	4.701,63	3.502,16	3.609,05	3.037,93	3.135,19	3.138,17	3.209,28	3.466,22	3.805,49
44	Krapina	2.004,04	2.004,98	2.211,24	3.106,60	3.028,09	2.587,69	2.375,78	2.218,99	2.373,37	2.439,63	2.412,73	2.573,46	2.929,48
45	Križevci	1.297,73	1.161,34	1.666,42	2.047,74	2.514,80	2.517,03	2.373,67	2.578,86	2.608,75	2.649,33	2.948,24	2.667,54	3.834,20
46	Krk	6.205,24	6.801,50	7.209,66	7.872,04	8.474,68	9.343,86	7.427,02	8.170,92	7.813,23	8.876,15	9.410,55	7.800,93	7.605,57
47	Kutina	1.838,44	2.267,10	2.488,91	3.233,48	3.368,36	3.485,82	3.235,41	3.495,96	3.166,38	3.112,85	3.484,57	3.299,69	3.207,32
48	Labin	3.166,25	3.333,83	3.905,94	4.690,61	5.270,55	4.523,51	5.105,92	5.180,50	4.994,03	5.383,61	5.698,01	5.462,92	5.580,06
49	Lepoglava	1.859,64	1.360,18	1.880,16	2.758,75	2.946,51	2.355,07	2.097,21	1.906,57	2.158,20	2.158,78	2.611,19	2.002,70	1.528,44
50	Lipik	2.041,74	1.949,00	2.053,44	2.712,91	2.558,59	3.442,02	2.293,12	2.627,42	2.785,80	2.579,70	3.429,69	3.302,79	3.189,78
51	Ludbreg	1.453,78	1.682,65	1.923,65	2.392,31	2.467,69	2.196,04	2.134,52	2.124,24	2.189,50	2.053,38	2.407,08	2.442,35	6.062,33
52	Makarska	3.803,96	3.583,49	4.163,17	4.948,73	5.358,34	5.052,74	4.264,70	4.337,54	5.442,63	4.555,66	4.706,93	4.692,48	5.086,35
53	Mali Lošinj	4.423,70	4.623,76	5.433,63	6.047,64	7.058,57	6.437,40	6.174,47	5.569,54	6.238,29	8.223,48	7.388,98	7.572,53	7.677,98
54	Metković	1.523,88	1.529,24	1.559,11	1.790,03	2.383,13	1.805,02	2.364,57	2.596,57	1.518,20	1.538,28	1.687,34	1.638,16	1.604,17

55	Mursko Središće	1.066,08	1.006,85	1.257,51	1.271,30	1.641,86	1.541,45	1.308,90	1.354,27	1.137,50	1.347,20	1.506,87	2.091,98	3.522,18
56	Našice	1.254,94	1.585,36	1.893,65	1.997,96	2.124,39	1.941,46	2.270,57	2.311,95	2.061,68	2.182,29	2.359,10	2.509,54	2.743,64
57	Nin	6.053,85	5.990,71	7.427,09	7.206,37	6.566,70	5.580,51	5.199,81	5.233,65	5.514,27	6.211,33	6.680,47	6.255,93	6.715,93
58	Nova Gradiška	1.277,10	1.558,65	1.637,90	2.311,83	2.168,84	2.479,06	2.368,26	1.792,00	1.694,41	2.176,04	1.985,86	3.351,92	3.671,99
59	Novalja	8.594,70	8.584,33	9.091,07	11.139,72	10.860,19	8.981,65	7.064,67	8.699,72	9.011,98	8.072,51	9.943,85	10.255,11	12.327,84
60	Novi Marof	1.040,79	1.262,59	1.155,44	1.385,97	1.591,13	1.465,97	1.586,43	1.293,88	1.241,99	1.313,03	1.323,20	1.333,91	1.440,03
61	Novi Vinodolski	3.892,87	4.472,73	8.288,88	5.768,58	6.343,94	4.596,54	5.227,89	5.340,88	5.788,96	5.145,16	5.252,70	5.280,40	5.723,18
62	Novigrad-Cittanova	6.993,21	8.779,97	9.496,61	10.025,19	9.154,61	8.417,46	9.947,41	9.316,31	7.803,64	7.252,08	7.862,99	8.195,62	9.779,80
63	Novska	1.883,29	1.922,00	2.213,85	2.727,75	2.738,54	2.519,30	2.622,64	2.529,59	2.754,00	2.968,04	2.732,32	3.207,53	3.092,69
64	Obrovac	2.168,08	2.722,23	2.913,01	3.645,44	4.191,50	3.469,67	4.134,19	3.574,61	2.924,68	3.651,05	3.646,38	5.270,46	4.841,78
65	Ogulin	3.369,34	2.451,74	5.138,88	3.697,85	3.692,32	3.558,32	3.065,53	2.857,33	2.776,77	2.914,30	2.887,29	2.736,53	2.566,41
66	Omiš	1.422,32	1.912,99	1.971,90	2.292,60	2.817,12	2.769,80	2.356,53	2.476,77	2.354,17	3.019,64	3.210,38	3.018,79	3.709,38
67	Opatija	6.296,58	6.492,57	7.247,37	8.203,57	9.569,17	9.084,10	7.976,42	7.269,83	7.785,91	8.374,28	9.312,48	8.657,69	8.723,57
68	Opuzen	2.015,57	2.113,60	2.115,92	2.027,78	3.423,05	3.348,75	3.487,69	3.459,16	1.884,52	2.171,87	2.475,29	2.746,41	2.128,23
69	Orahovica	2.946,40	2.637,09	2.876,96	4.214,25	4.009,80	4.367,40	3.421,69	3.490,64	3.840,85	3.528,56	4.109,79	2.963,54	2.736,19
70	Oroslavje	1.206,36	1.119,05	1.120,92	1.638,09	1.918,92	1.747,22	1.683,86	1.677,11	1.838,09	1.970,12	2.069,46	2.109,81	2.199,36
71	Osijek	2.649,39	2.946,84	3.630,93	3.637,56	4.098,42	4.292,99	3.752,07	3.424,90	3.481,65	3.429,41	3.531,48	3.189,28	3.325,37
72	Otočac	2.956,12	2.125,81	2.221,00	2.815,52	3.913,77	3.084,63	2.334,70	2.144,26	2.312,82	2.382,97	2.845,22	2.794,74	3.328,15
73	Otok	1.166,42	1.491,71	1.932,52	2.144,62	2.499,99	2.437,57	2.560,12	2.041,26	1.894,56	1.765,09	2.150,71	2.291,23	2.576,19
74	Ozalj	866,64	1.004,73	1.303,68	1.654,05	1.772,08	1.658,06	1.605,65	1.703,39	1.985,74	2.204,15	2.244,46	1.979,97	4.343,76
75	Pag	4.273,19	3.765,56	4.921,07	4.358,44	5.500,23	4.941,25	5.036,65	4.294,43	5.364,88	4.988,74	5.357,91	6.239,32	8.015,23
76	Pakrac	2.129,11	1.745,72	1.864,29	2.314,14	2.977,11	2.435,70	3.423,48	2.404,43	2.978,59	2.185,81	4.457,75	2.637,73	3.022,63
77	Pazin	3.284,41	3.533,49	3.896,79	5.017,91	5.270,47	5.594,96	5.095,66	5.603,62	4.902,82	6.375,00	6.876,78	5.720,73	5.732,88
78	Petrinja	1.767,65	1.654,89	2.147,40	2.547,60	2.793,94	2.833,48	2.802,48	2.606,70	2.574,63	2.697,08	2.878,12	2.914,80	3.180,84
79	Pleternica	643,48	652,95	1.285,82	1.707,40	1.173,51	1.057,37	1.704,93	1.371,30	1.778,87	1.529,52	2.074,83	1.863,50	2.014,47
80	Ploče	1.181,35	1.330,09	1.214,81	2.622,84	2.804,71	2.690,52	2.261,31	2.802,49	2.268,36	2.444,13	2.270,00	2.722,61	2.306,87
81	Poreč	5.464,51	7.004,38	7.225,81	7.778,19	8.602,29	8.351,56	7.102,25	7.335,72	6.275,06	6.511,56	7.594,02	8.122,62	7.432,99
82	Požega	1.795,02	1.764,21	1.927,27	2.322,26	2.734,80	2.537,23	2.414,10	2.422,26	2.562,63	3.402,82	2.718,36	2.539,84	2.536,73

83	Pregrada	1.180,12	1.121,08	1.866,79	2.855,89	2.440,29	1.888,30	1.539,65	1.471,59	1.451,86	1.683,59	1.878,29	1.744,18	1.820,55
84	Prelog	1.219,24	1.474,96	1.975,69	2.043,56	2.258,55	1.832,44	1.884,73	1.810,43	1.995,26	1.858,56	2.191,82	2.446,23	2.314,27
85	Pula	3.567,89	3.332,71	3.933,53	4.866,84	4.922,50	4.757,92	4.506,26	4.442,25	4.365,54	4.768,40	4.615,60	4.611,99	5.113,65
86	Rab	3.808,83	4.822,94	5.488,86	5.316,08	6.190,23	5.485,28	5.012,33	4.258,31	5.130,42	4.875,00	4.232,14	4.265,11	4.220,18
87	Rijeka	3.498,84	4.099,28	4.503,24	5.545,70	5.404,83	5.209,93	5.117,90	4.825,52	5.190,75	5.141,08	5.175,06	5.344,46	5.352,07
88	Rovinj	6.980,48	7.570,37	7.160,39	7.893,72	7.461,15	7.094,12	6.612,45	6.249,56	6.913,75	6.963,51	8.118,27	8.983,44	8.456,80
89	Samobor	2.715,35	2.663,43	3.014,37	4.151,67	4.912,78	4.299,38	4.015,37	3.630,71	4.070,78	4.195,39	4.461,67	5.515,80	5.406,72
90	Senj	2.813,37	2.744,09	2.719,16	3.917,12	4.230,85	3.866,50	3.567,06	3.538,50	4.458,97	4.956,20	5.612,19	4.500,92	4.413,42
91	Sinj	1.915,02	1.859,66	2.287,39	2.479,79	3.084,17	2.713,03	2.466,10	2.405,97	2.279,88	2.286,31	2.201,79	1.927,96	1.822,99
92	Sisak	2.461,31	2.814,63	3.125,26	4.484,49	4.689,50	4.495,63	4.301,67	3.935,99	3.726,40	3.524,29	3.625,21	3.669,40	3.813,97
93	Skradin	1.942,69	2.699,07	1.942,90	2.429,37	3.120,32	2.869,90	2.588,86	2.306,77	2.107,92	3.799,77	2.932,74	3.096,69	3.697,47
94	Slatina	1.288,57	1.649,20	1.871,00	2.353,74	2.025,17	1.844,87	2.200,17	1.895,59	1.953,51	2.033,48	2.324,40	2.164,92	2.456,66
95	Slavonski Brod	1.489,57	1.644,50	1.683,30	2.208,01	2.346,13	2.648,75	2.636,02	2.279,02	2.086,19	2.184,09	2.241,33	2.344,65	2.542,20
96	Slunj	1.987,88	2.134,58	1.538,47	4.226,50	3.073,90	3.162,63	3.169,54	3.021,44	3.409,90	3.289,67	3.053,87	2.926,78	3.255,50
97	Solin	2.636,81	2.788,32	3.477,45	3.805,83	4.293,52	3.672,15	2.897,94	3.382,70	3.206,67	3.316,19	3.091,79	3.360,13	3.105,77
98	Split	2.736,82	2.965,39	3.434,30	3.940,76	4.621,77	4.840,18	4.108,32	3.955,59	3.777,40	4.068,38	4.011,95	3.832,71	4.080,37
99	Stari Grad	3.224,17	3.534,86	5.113,94	6.474,23	5.475,70	4.988,47	4.110,63	4.058,88	3.569,50	4.404,28	6.093,68	4.863,78	5.421,45
100	Supetar	4.490,03	4.936,70	4.757,14	6.887,49	6.637,43	5.399,12	4.550,81	4.335,22	3.601,09	5.048,96	5.440,19	5.040,07	5.261,32
101	Sveta Nedelja	2.402,32	3.499,35	4.985,60	5.076,23	4.433,03	3.727,54	3.240,80	3.862,77	3.464,90	3.613,12	5.005,87	4.269,72	4.377,86
102	Sveti Ivan Zelina	1.373,84	1.310,50	2.097,49	3.169,40	2.822,38	2.167,29	2.086,43	1.929,23	2.030,84	1.976,35	2.022,38	2.032,19	2.223,96
103	Šibenik	2.010,33	2.263,00	2.409,00	3.354,97	3.664,49	3.305,80	3.847,59	3.223,79	4.036,27	3.565,36	3.969,62	3.490,84	3.551,52
104	Trilj	1.262,66	1.454,03	1.675,04	2.000,79	2.126,30	2.585,28	2.320,98	1.519,67	1.556,47	1.837,22	1.996,43	2.907,54	2.643,72
105	Trogir	2.381,79	2.655,46	3.786,20	4.206,12	4.906,04	4.152,10	3.320,73	3.715,57	3.775,27	3.822,31	4.128,02	3.863,36	4.639,62
106	Umag	6.633,34	6.369,03	7.198,55	9.228,32	9.051,35	8.751,66	9.846,31	7.762,95	7.039,25	7.066,23	7.185,12	7.209,07	9.674,52
107	Valpovo	1.470,38	1.463,08	1.247,63	1.888,94	1.923,50	2.112,57	1.893,30	1.969,54	1.937,08	1.815,65	1.707,96	1.675,21	1.760,06
108	Varaždin	3.174,21	3.397,22	3.933,34	4.494,25	4.880,45	4.959,74	4.395,96	4.079,11	4.117,21	4.828,49	4.659,20	4.516,38	4.788,92
109	Varaždinske Toplice	947,28	895,04	1.469,09	1.865,04	1.933,35	1.726,81	1.511,47	1.507,21	1.517,82	1.519,55	1.801,59	1.725,84	2.121,29
110	Velika Gorica	2.463,68	2.709,50	2.994,17	3.899,45	4.075,18	3.881,47	3.806,99	3.360,27	3.666,81	3.743,00	3.565,51	4.139,18	3.816,77

111	Vinkovci	1.903,12	1.918,45	2.190,58	2.709,23	2.949,50	2.719,31	3.163,52	2.195,45	2.365,70	2.567,72	2.496,74	2.379,03	3.278,79
112	Virovitica	1.890,23	2.225,14	2.755,92	3.698,20	3.292,76	3.334,51	3.137,42	3.091,05	2.991,79	2.996,97	3.200,60	2.903,60	2.999,05
113	Vis	3.208,79	3.501,46	4.541,52	7.266,36	5.643,70	5.095,21	4.728,35	5.436,56	4.536,33	9.189,19	8.405,43	6.302,79	7.645,55
114	Vodice	3.761,89	5.328,97	6.286,64	5.234,35	5.305,12	4.185,53	4.400,07	3.933,45	4.783,70	4.973,64	5.197,48	5.566,64	5.660,42
115	Vodnjan	3.885,39	3.637,33	4.455,93	5.717,07	7.489,48	5.685,23	4.743,80	5.052,37	4.318,72	6.834,47	5.729,59	5.899,46	5.996,36
116	Vrbovec	1.589,51	1.745,70	1.662,34	2.256,16	2.516,80	2.437,49	2.165,49	2.208,13	1.941,62	2.379,29	2.338,23	2.317,85	2.282,18
117	Vrbovsko	2.863,43	3.021,72	3.813,33	5.335,25	4.917,40	3.658,93	3.222,74	2.982,21	3.290,89	3.387,51	3.833,56	3.318,45	3.359,51
118	Vrgorac	1.753,17	2.779,75	2.866,67	4.688,35	5.051,89	5.361,49	5.470,49	4.805,38	3.303,13	2.590,77	2.697,53	2.183,86	2.627,11
119	Vrlika	3.052,30	4.790,23	4.566,93	4.542,22	3.949,13	4.791,70	4.427,20	8.142,58	4.972,96	4.646,60	6.388,55	5.676,58	4.984,76
120	Vukovar	1.766,07	2.473,59	2.771,39	3.143,28	3.608,85	3.600,55	3.868,56	3.117,60	3.540,99	3.923,91	4.349,52	3.596,95	5.842,21
121	Zabok	1.845,83	2.117,87	2.653,35	3.397,82	3.898,95	3.757,43	3.524,58	3.325,99	3.557,88	4.027,23	3.875,69	3.845,10	3.933,41
122	Zadar	2.565,95	3.206,79	3.653,19	5.089,63	4.583,55	4.409,54	3.910,23	3.833,01	4.292,82	4.202,61	4.570,00	4.501,65	4.886,47
123	Zagreb	6.152,59	6.894,41	7.766,07	8.241,77	9.060,88	8.480,97	7.833,21	7.586,32	7.801,78	8.917,97	8.259,77	7.688,26	7.934,03
124	Zaprešić	3.461,44	4.644,64	4.201,97	5.405,98	7.456,47	7.433,57	5.049,48	5.256,08	4.389,05	4.653,97	4.848,53	4.741,58	4.936,91
125	Zlatar	997,50	1.080,10	1.135,73	1.428,79	1.662,75	1.792,32	2.138,98	1.497,22	1.981,67	1.748,51	1.887,33	1.975,31	2.216,31
126	Županja	1.627,51	1.514,23	1.754,68	2.225,31	2.498,29	2.035,22	2.063,07	1.979,88	1.983,20	2.114,55	2.668,58	2.127,65	2.452,19

Izvor: Ministarstvo financija i Državni zavod za statistiku

Prilog 4 Broj poduzetnika u gradovima

Rbr	Ime grada	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016
1	Bakar	13.145	13.308	14.889	15.662	16.019	17.274	17.701	17.939	18.794	18.490	19.666	20.944
2	Beli Manastir	6.640	8.415	8.081	9.464	8.546	8.827	9.610	8.059	9.843	11.781	12.067	12.453
3	Belišće	3.741	4.051	3.662	4.201	4.172	5.094	4.998	5.074	5.218	6.636	7.212	7.839
4	Benkovac	4.251	4.843	5.119	5.710	5.171	6.449	7.175	6.912	7.449	8.190	8.740	9.518
5	Biograd na Moru	15.275	16.491	16.334	18.296	17.729	20.186	21.318	22.338	22.815	26.314	28.066	29.588
6	Bjelovar	9.953	11.051	11.367	12.081	11.986	12.907	13.998	13.820	15.578	16.101	16.015	18.069
7	Buje	36.909	44.144	43.822	44.740	44.513	44.732	46.294	47.854	49.184	49.531	48.662	62.518
8	Buzet	25.578	26.073	25.517	28.737	29.821	29.366	30.695	30.872	31.838	32.830	32.822	33.834
9	Cres	15.795	17.105	18.745	19.262	16.222	19.213	20.473	21.794	22.128	22.733	25.102	26.853
10	Crikvenica	13.735	14.663	14.941	15.989	16.838	17.808	18.432	17.865	19.707	21.364	22.374	23.214
11	Čabar	5.995	7.511	7.876	8.543	8.838	9.795	10.604	10.588	10.715	10.947	10.538	10.437
12	Čakovec	23.775	25.438	26.661	27.834	26.759	28.783	29.060	27.667	29.274	31.509	31.631	35.469
13	Čazma	8.482	8.420	9.307	9.332	9.117	8.973	9.191	9.701	10.591	10.434	11.620	12.888
14	Daruvar	9.707	10.367	11.056	11.058	10.966	11.579	11.021	11.103	11.503	12.908	12.629	14.013
15	Delnice	11.751	13.766	15.957	15.816	17.373	18.688	17.958	16.873	18.338	18.698	17.595	17.120
16	Donja Stubica	6.697	8.354	8.390	8.943	9.610	10.421	10.756	10.646	11.768	11.961	11.659	12.451
17	Donji Miholjac	7.172	7.409	7.882	8.810	9.045	9.555	9.398	9.850	11.068	11.322	11.949	12.537
18	Drniš	7.462	8.210	8.831	10.243	11.307	11.941	11.782	11.493	11.220	11.218	11.189	13.605
19	Dubrovnik	24.858	27.080	29.068	29.863	31.218	32.706	33.831	34.274	34.926	36.295	36.109	36.681
20	Duga Resa	8.382	8.367	9.116	9.861	9.435	10.074	9.820	9.175	9.983	11.700	11.973	12.454
21	Dugo Selo	12.479	14.711	16.408	17.960	16.810	17.074	16.896	16.786	17.648	19.254	18.848	20.287
22	Đakovo	8.689	9.493	9.855	10.531	10.997	11.536	11.826	11.542	11.887	12.130	12.230	12.739
23	Đurđevac	11.091	11.622	12.688	12.251	11.972	11.986	11.239	11.618	11.621	11.573	11.990	12.813
24	Garešnica	9.296	9.589	10.228	10.152	11.429	12.021	11.540	10.904	12.845	12.813	12.707	13.353
25	Glina	2.082	2.939	3.129	3.540	3.962	4.290	4.237	4.954	5.732	5.407	6.353	7.485
26	Gospić	7.087	8.239	8.487	8.717	8.906	10.762	10.698	11.632	11.714	12.769	13.547	13.653

27	Grubišno Polje	6.175	6.855	7.832	8.841	8.909	10.051	10.997	10.699	10.049	11.466	11.512	11.471
28	Hrvatska Kostajnica	5.565	5.169	5.894	6.640	5.980	8.758	8.550	8.259	8.327	8.649	8.665	11.340
29	Hvar	15.303	19.008	20.349	19.719	20.976	21.010	21.348	19.990	20.339	25.941	26.351	30.757
30	Ilok	4.712	5.135	5.355	5.765	6.954	7.891	7.738	6.517	6.561	7.054	7.227	7.330
31	Imotski	9.755	10.460	11.247	13.511	13.173	13.654	12.784	13.205	14.070	14.290	13.473	14.515
32	Ivanec	8.199	8.574	9.014	9.303	10.225	10.441	10.628	10.326	10.373	10.652	12.267	13.690
33	Ivanić-Grad	11.108	11.594	12.694	13.900	13.578	14.101	15.000	14.629	16.145	17.329	17.605	19.311
34	Jastrebarsko	9.379	10.439	10.897	11.951	12.217	12.835	12.939	12.739	13.107	14.118	14.073	16.501
35	Karlovac	12.025	12.768	13.262	13.622	14.008	14.658	14.630	13.935	14.594	15.637	15.670	16.368
36	Kastav	18.923	20.822	21.449	22.835	25.574	25.685	26.504	25.308	25.835	26.497	28.221	29.536
37	Kaštela	6.912	7.054	7.840	8.297	9.252	9.286	10.033	10.333	11.532	12.069	12.242	13.658
38	Klanjec	7.199	8.279	9.401	9.721	9.580	11.095	11.786	12.728	14.069	17.429	15.071	15.850
39	Knin	2.455	2.729	3.178	3.642	3.492	3.823	4.033	4.156	4.198	4.614	4.590	4.850
40	Komiža	12.477	14.041	16.663	16.224	21.088	21.762	21.681	19.839	22.221	21.080	21.033	21.966
41	Koprivnica	9.626	10.236	10.075	12.131	11.714	12.472	12.854	12.499	12.150	13.672	13.631	17.568
42	Korčula	11.847	12.659	15.049	15.388	15.704	17.015	17.892	16.356	16.982	17.553	18.346	20.417
43	Kraljevica	9.711	10.355	9.618	10.931	10.346	12.133	11.487	11.077	12.116	12.089	13.474	15.410
44	Krapina	10.826	12.556	13.162	13.686	14.124	14.359	13.976	14.151	15.500	17.360	17.738	18.481
45	Križevci	12.191	13.564	13.000	13.663	13.193	14.132	14.123	14.341	15.132	15.978	16.842	16.625
46	Krk	20.397	24.799	26.988	29.428	29.513	29.223	29.075	28.176	30.766	32.270	33.134	31.917
47	Kutina	8.583	8.854	9.505	10.079	10.406	10.901	11.067	11.344	12.527	12.741	13.015	13.690
48	Labin	21.524	23.769	26.776	27.777	28.845	29.585	30.468	31.310	29.889	32.737	34.053	34.306
49	Lepoglava	5.285	5.602	5.458	5.413	5.664	5.996	5.583	5.354	5.610	6.108	6.485	8.568
50	Lipik	3.447	4.084	4.226	4.162	4.738	5.101	5.913	5.455	6.361	6.810	7.201	7.165
51	Ludbreg	12.215	14.261	14.398	15.152	15.600	15.423	16.170	16.075	15.458	15.131	15.485	16.802
52	Makarska	16.531	18.441	19.328	20.945	19.587	22.144	23.450	22.723	23.651	25.884	27.225	29.750
53	Mali Lošinj	19.714	22.425	25.483	26.624	25.242	25.846	25.962	25.135	25.246	28.281	29.803	30.106
54	Metković	10.294	11.378	12.131	12.681	13.284	12.695	13.228	13.380	13.771	15.147	14.803	15.267
55	Mursko Središće	8.608	9.793	10.082	11.708	11.770	12.368	12.717	12.343	13.571	15.409	16.633	18.038

56	Našice	6.109	7.043	7.468	8.727	8.930	8.794	9.056	8.773	8.960	10.116	10.857	11.548
57	Nin	7.077	8.688	9.402	9.518	8.044	10.628	11.210	10.137	11.184	13.174	12.538	15.200
58	Nova Gradiška	7.547	7.881	7.937	6.830	8.371	9.024	8.674	8.466	9.914	10.547	11.855	13.401
59	Novalja	8.278	12.842	16.401	15.712	17.975	21.080	21.179	21.173	23.730	27.600	27.309	34.694
60	Novi Marof	5.149	6.858	7.041	7.416	7.984	8.521	8.228	8.598	8.939	9.373	9.828	10.764
61	Novi Vinodolski	9.899	11.486	12.664	12.844	12.701	13.266	13.576	14.588	14.832	16.031	16.242	17.460
62	Novigrad-Cittanova	41.790	46.589	51.235	51.935	54.892	54.446	57.417	58.158	58.966	59.609	60.326	65.102
63	Novska	4.576	5.156	5.765	5.684	6.447	6.692	7.233	7.348	7.607	7.893	8.304	8.777
64	Obrovac	3.839	5.151	8.709	10.441	10.767	11.130	10.115	9.813	10.092	10.653	10.632	10.636
65	Ogulin	6.548	7.768	8.401	8.930	8.492	9.737	9.032	9.651	9.441	10.080	10.961	11.035
66	Omiš	7.220	8.452	9.091	9.660	9.216	9.935	10.336	11.318	11.048	12.132	12.888	13.833
67	Opatija	30.089	33.299	37.323	41.376	41.787	44.430	42.569	43.145	43.186	43.392	45.366	46.870
68	Opuzen	9.275	10.956	11.726	12.869	13.618	13.807	14.831	14.593	13.645	14.610	14.085	13.462
69	Orahovica	7.137	8.607	9.121	9.580	9.367	9.528	10.815	10.242	10.347	11.672	12.597	12.277
70	Oroslavje	8.216	9.292	8.885	8.779	8.717	9.655	11.361	11.417	11.987	12.292	14.300	18.391
71	Osijek	13.369	14.046	14.632	15.049	15.296	16.268	16.222	15.927	16.980	18.055	18.800	19.900
72	Otočac	8.792	8.544	8.936	9.447	9.809	9.677	9.823	9.538	10.290	10.486	9.976	10.810
73	Otok	1.861	2.483	2.519	2.659	3.432	3.232	3.641	4.192	4.495	5.055	3.433	5.992
74	Ozalj	6.724	7.474	7.108	9.321	9.454	10.616	11.597	12.441	13.909	13.881	14.024	15.396
75	Pag	9.522	9.124	10.362	10.076	9.732	9.203	10.547	11.006	10.670	12.390	12.918	12.598
76	Pakrac	5.608	6.259	6.445	6.342	6.677	6.977	6.968	7.283	8.540	8.705	9.236	10.290
77	Pazin	17.117	20.997	21.760	23.477	25.364	26.672	27.018	25.922	27.300	29.170	27.718	29.047
78	Petrinja	3.614	4.021	4.676	5.004	5.380	5.931	6.337	5.985	6.420	6.783	7.802	8.462
79	Pleternica	2.653	2.623	3.588	4.229	4.499	5.209	5.716	5.934	6.012	6.308	6.238	7.424
80	Ploče	7.929	8.469	8.664	9.178	9.268	9.718	9.532	10.253	11.040	10.763	11.490	12.308
82	Poreč	37.557	47.149	49.532	54.264	52.996	58.493	56.924	60.057	59.373	59.562	60.290	59.123
83	Požega	7.341	7.953	8.011	7.826	7.682	8.434	8.827	8.607	9.193	9.994	11.004	13.306
84	Pregrada	6.299	7.383	8.622	8.581	9.467	10.053	10.392	9.870	10.007	9.784	9.687	11.488
85	Prelog	13.821	16.428	18.217	21.461	18.376	20.581	21.658	19.853	21.235	24.393	25.843	27.972

86	Pula	21.931	24.200	27.879	30.089	30.691	32.551	34.357	32.855	34.055	37.039	36.850	38.159
87	Rab	15.644	16.451	16.450	17.445	17.351	18.123	18.264	17.516	17.378	18.253	18.264	19.823
88	Rijeka	19.779	21.392	22.846	24.167	24.347	25.089	25.413	25.354	26.566	27.745	28.112	28.826
89	Rovinj	34.305	39.942	43.421	47.347	48.985	49.115	45.342	43.609	44.255	44.484	46.079	49.161
90	Samobor	14.919	16.528	17.457	18.761	18.788	20.204	20.568	20.838	20.267	22.581	22.345	24.367
91	Senj	7.196	8.090	9.076	9.858	9.793	10.568	10.692	10.591	11.991	11.902	12.946	13.106
92	Sinj	6.778	7.182	7.094	6.981	7.077	7.738	7.910	7.552	7.405	8.051	8.333	9.062
93	Sisak	7.335	8.243	8.721	9.844	10.267	10.489	10.908	10.718	11.337	12.006	12.372	13.192
94	Skradin	6.067	7.669	6.913	8.999	9.529	10.271	12.416	12.267	9.494	9.693	10.217	12.002
95	Slatina	8.743	9.263	9.415	9.973	10.683	11.620	12.578	11.735	12.480	12.624	12.172	12.785
96	Slavonski Brod	9.281	9.581	9.738	10.034	10.632	11.576	11.824	11.022	12.145	12.983	13.453	14.785
97	Slunj	4.319	5.087	5.603	6.947	9.067	10.199	10.690	10.354	10.565	10.453	10.205	11.794
98	Solin	11.709	12.997	13.161	15.443	15.223	16.084	15.994	15.034	15.877	16.632	17.178	18.778
99	Split	19.111	21.076	22.459	25.317	25.543	26.889	27.806	27.349	28.450	29.493	29.900	31.127
100	Stari Grad	12.267	14.242	12.643	10.841	12.853	14.792	15.102	13.478	17.665	19.663	16.491	26.078
101	Supetar	24.909	27.701	32.106	34.015	36.080	35.442	32.939	33.292	34.606	35.321	34.354	37.230
102	Sveta Nedelja	17.030	19.189	19.832	20.986	23.111	26.905	27.071	26.759	28.194	26.224	28.519	31.359
103	Sveti Ivan Zelina	11.750	13.135	14.159	14.213	16.058	16.012	16.003	15.559	16.952	16.571	18.500	21.110
104	Šibenik	11.513	12.384	12.781	15.059	15.024	16.701	16.749	16.842	17.469	18.515	18.382	19.641
105	Trilj	4.149	4.840	5.629	6.598	7.170	7.300	8.145	7.986	8.372	8.264	8.087	9.504
106	Trogir	12.382	17.457	20.708	22.943	21.464	23.237	22.867	20.945	21.065	22.980	23.029	23.299
107	Umag	45.662	51.805	55.235	56.350	54.214	55.061	54.249	54.027	55.362	53.696	55.041	56.025
108	Valpovo	5.975	6.484	6.780	7.056	7.165	7.430	7.586	8.179	8.258	8.453	8.234	9.699
109	Varaždin	19.311	20.645	22.081	24.885	24.932	25.343	25.627	25.377	27.050	28.126	29.169	31.872
110	Varaždinske Toplice	4.970	5.746	6.328	7.269	7.961	8.078	8.578	8.080	9.302	11.159	10.868	11.080
111	Velika Gorica	11.436	12.414	13.131	13.800	13.823	14.761	15.503	15.216	15.366	15.741	16.581	17.983
112	Vinkovci	9.110	9.559	9.465	9.848	10.063	10.966	11.898	11.276	10.926	11.435	11.740	12.932
113	Virovitica	7.622	8.466	7.704	8.512	9.036	9.670	9.537	9.313	10.108	10.624	11.468	13.918
114	Vis	17.310	20.236	25.849	29.840	30.318	32.390	35.195	36.041	36.077	40.945	46.860	47.553

115	Vodice	15.725	16.824	18.627	23.321	22.250	24.370	24.457	23.691	23.611	24.804	23.713	24.830
116	Vodnjan	12.676	14.710	17.029	17.642	19.516	19.555	20.120	20.141	19.548	19.170	21.585	24.667
117	Vrbovec	11.316	11.760	12.105	13.037	13.791	13.913	14.404	15.127	16.117	15.907	15.450	17.204
118	Vrbovsko	9.200	10.394	11.893	13.120	13.527	13.342	12.821	11.182	11.631	11.710	12.778	13.572
119	Vrgorac	3.640	4.989	5.434	6.823	7.549	8.190	8.791	8.504	8.530	8.742	7.863	10.615
120	Vrlika	3.432	3.184	3.266	6.027	7.659	8.982	7.908	6.670	6.579	6.438	7.059	8.554
121	Vukovar	6.630	7.785	8.761	9.575	9.972	10.808	11.016	11.044	11.761	12.794	13.978	15.065
122	Zabok	10.694	12.731	14.447	15.356	14.754	15.818	15.586	15.201	16.047	18.208	18.407	19.455
123	Zadar	12.139	13.788	15.172	17.219	16.830	18.947	19.182	19.132	19.812	22.251	22.505	24.353
124	Zagreb	24.467	25.973	27.469	29.273	29.362	31.554	32.144	32.026	33.329	34.336	35.089	38.127
125	Zaprešić	14.489	15.693	15.994	17.811	17.665	18.687	19.258	19.120	19.852	20.173	20.889	22.436
126	Zlatar	7.261	7.813	8.360	8.981	8.976	9.337	10.673	10.625	11.154	12.732	13.276	14.846
127	Županja	7.880	8.426	8.593	9.077	8.576	9.669	10.516	9.549	9.396	10.018	10.665	11.854

Izvor: Varijabla će se mjeriti aktivnim brojem poduzetnika prema podacima iz registra Fine normaliziranim brojem stanovnika na temelju podataka Državnog zavoda za statistiku, pri čemu je Grad Zagreb=100. Financijska agencija i Državni zavod za statistiku

Prilog 5 Stopa nezaposlenost u gradovima

Rbr	Ime grada	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016
1	Bakar	6,92%	6,82%	5,79%	5,27%	4,31%	4,79%	5,87%	6,16%	6,53%	6,65%	6,64%	5,56%	4,33%
2	Beli Manastir	15,78%	15,43%	14,91%	13,75%	13,18%	14,10%	15,18%	15,51%	16,39%	17,20%	17,15%	16,31%	15,02%
3	Belišće	10,83%	11,31%	11,37%	11,17%	10,92%	13,11%	13,49%	13,23%	13,75%	15,65%	15,53%	13,96%	12,23%
4	Benkovac	6,59%	6,04%	5,90%	5,40%	4,31%	4,33%	4,67%	4,26%	4,97%	5,69%	4,93%	4,49%	4,17%
5	Biograd na Moru	6,44%	5,35%	4,96%	4,55%	3,86%	4,35%	4,36%	3,86%	3,83%	4,62%	4,04%	4,02%	3,77%
6	Bjelovar	8,07%	8,42%	8,46%	7,92%	7,22%	7,90%	8,95%	8,68%	8,93%	9,67%	9,78%	8,86%	7,11%
7	Buje	1,34%	1,55%	1,62%	1,48%	1,27%	1,91%	2,74%	2,96%	3,04%	3,77%	3,94%	2,75%	2,25%
8	Buzet	1,15%	1,55%	1,42%	1,09%	1,32%	2,26%	3,22%	3,37%	3,70%	3,79%	2,87%	2,05%	2,03%
9	Cres	1,91%	1,80%	1,89%	2,23%	1,85%	1,81%	2,49%	2,23%	2,07%	2,41%	2,28%	1,94%	1,85%
10	Crikvenica	6,91%	6,05%	5,76%	5,06%	3,89%	4,46%	5,07%	5,28%	5,41%	5,60%	5,50%	4,60%	4,04%
11	Čabar	4,18%	5,43%	5,41%	4,10%	4,05%	4,89%	5,33%	4,60%	4,83%	6,11%	7,37%	7,22%	6,70%
12	Čakovec	8,12%	7,77%	6,86%	5,70%	4,79%	5,44%	6,35%	6,17%	6,81%	7,05%	6,53%	5,25%	4,40%
13	Čazma	11,28%	11,35%	10,64%	9,93%	8,90%	9,81%	10,63%	9,74%	10,06%	10,47%	10,00%	9,57%	7,70%
14	Daruvar	7,30%	7,79%	7,69%	7,56%	6,84%	8,03%	8,95%	9,25%	9,54%	9,36%	9,34%	8,21%	6,60%
15	Delnice	8,30%	7,90%	8,08%	7,26%	6,45%	7,31%	8,32%	7,33%	7,23%	8,42%	7,84%	7,69%	6,43%
16	Donja Stubica	4,06%	4,26%	3,80%	2,91%	2,20%	3,11%	4,37%	5,15%	6,00%	6,68%	6,36%	5,23%	3,91%
17	Donji Miholjac	11,89%	11,62%	11,12%	10,15%	8,81%	9,15%	11,23%	10,73%	11,38%	11,74%	11,63%	10,63%	8,86%
18	Drniš	8,03%	7,68%	6,81%	5,92%	5,49%	5,90%	6,34%	6,56%	6,88%	7,19%	6,98%	6,43%	5,98%
19	Dubrovnik	6,34%	5,77%	5,22%	4,97%	4,15%	4,60%	5,13%	4,76%	4,60%	4,63%	4,51%	4,21%	3,40%
20	Duga Resa	13,85%	14,15%	13,78%	13,10%	12,93%	14,82%	14,96%	13,53%	11,94%	11,27%	10,22%	8,96%	7,23%
21	Dugo Selo	5,92%	5,99%	5,92%	4,94%	4,16%	4,70%	5,82%	6,07%	6,59%	7,54%	6,76%	6,38%	5,37%
22	Đakovo	8,00%	7,67%	7,05%	6,62%	6,12%	7,60%	9,96%	10,54%	11,14%	11,79%	11,04%	9,37%	8,07%
23	Đurđevac	9,07%	9,16%	8,61%	7,92%	7,16%	7,13%	8,22%	8,49%	9,74%	10,73%	9,56%	7,76%	6,02%
24	Garešnica	9,29%	10,39%	10,79%	9,88%	8,72%	10,97%	10,64%	9,47%	9,30%	10,07%	10,71%	10,97%	9,31%
25	Glina	13,79%	13,52%	13,00%	12,49%	11,85%	12,55%	13,08%	12,30%	12,54%	13,49%	13,82%	12,51%	11,77%
26	Gospić	5,44%	6,18%	6,12%	5,41%	4,81%	4,98%	5,30%	5,57%	5,58%	6,59%	7,35%	7,02%	6,88%

27	Grubišno Polje	14,20%	14,22%	14,13%	12,84%	12,97%	13,30%	13,49%	12,63%	12,16%	12,82%	13,62%	11,79%	10,17%
28	Hrvatska Kostajnica	13,77%	13,52%	12,58%	11,75%	11,79%	12,05%	13,31%	12,70%	13,08%	13,58%	13,49%	12,02%	10,46%
29	Hvar	4,38%	3,86%	4,15%	3,87%	3,81%	4,36%	4,59%	5,34%	5,28%	6,34%	5,27%	4,08%	4,01%
30	Ilok	10,81%	9,46%	8,47%	7,65%	6,73%	7,57%	7,33%	7,58%	9,01%	11,09%	10,79%	9,13%	8,08%
31	Imotski	12,47%	12,14%	12,32%	11,74%	11,32%	11,84%	12,65%	12,79%	14,16%	15,15%	15,09%	14,57%	13,93%
32	Ivanec	5,51%	5,65%	5,48%	4,82%	4,18%	4,97%	5,83%	6,19%	6,63%	7,21%	6,53%	5,36%	4,27%
33	Ivanić-Grad	6,72%	6,57%	6,11%	5,35%	4,48%	5,07%	5,98%	6,32%	6,98%	7,29%	7,50%	6,89%	5,88%
34	Jastrebarsko	3,90%	4,24%	4,19%	3,45%	2,77%	3,52%	3,80%	4,38%	4,50%	5,35%	5,08%	4,09%	3,56%
35	Karlovac	9,61%	9,69%	9,24%	8,45%	7,34%	7,41%	7,57%	7,29%	7,52%	7,79%	7,38%	6,58%	5,34%
36	Kastav	5,07%	5,07%	4,66%	4,10%	3,64%	4,42%	5,28%	5,30%	5,48%	5,86%	5,76%	4,48%	3,54%
37	Kaštela	10,30%	9,89%	9,40%	8,79%	7,99%	8,79%	9,73%	10,15%	11,29%	11,55%	10,38%	8,97%	7,78%
38	Klanjec	5,02%	5,85%	5,38%	4,99%	4,48%	5,10%	6,71%	6,84%	7,92%	8,37%	8,05%	7,16%	5,83%
39	Knin	16,47%	15,03%	13,74%	11,31%	9,12%	10,00%	11,39%	11,24%	12,24%	12,81%	12,11%	11,12%	10,08%
40	Komiža	12,03%	10,15%	10,00%	8,64%	9,09%	8,87%	9,90%	9,93%	10,27%	10,54%	11,25%	10,87%	9,63%
41	Koprivnica	7,07%	7,04%	6,64%	6,01%	5,10%	5,63%	6,15%	5,99%	6,75%	7,37%	6,98%	5,77%	4,65%
42	Korčula	6,79%	6,12%	5,68%	5,60%	5,43%	6,12%	6,45%	6,73%	7,05%	7,48%	7,42%	6,69%	5,92%
43	Kraljevica	4,76%	4,71%	4,07%	3,54%	3,22%	3,65%	4,42%	4,68%	6,35%	6,78%	5,89%	4,77%	3,89%
44	Krapina	6,59%	6,60%	6,06%	5,24%	4,47%	5,25%	6,44%	6,45%	6,93%	7,23%	7,22%	6,20%	5,23%
45	Križevci	5,57%	5,89%	5,06%	4,28%	3,44%	3,88%	5,34%	5,02%	5,70%	6,73%	5,55%	4,39%	3,22%
46	Krk	2,28%	2,47%	2,20%	2,18%	2,00%	2,26%	2,80%	2,91%	2,89%	2,98%	2,55%	2,26%	2,03%
47	Kutina	5,78%	5,97%	5,75%	5,05%	5,70%	7,71%	9,03%	8,48%	9,35%	10,15%	10,61%	9,94%	8,61%
48	Labin	4,78%	4,38%	4,78%	4,03%	3,58%	4,56%	5,26%	5,32%	5,54%	6,09%	5,09%	4,82%	3,88%
49	Lepoglava	4,92%	5,12%	5,24%	4,56%	4,07%	5,27%	6,28%	6,29%	6,78%	6,92%	6,79%	5,65%	4,50%
50	Lipik	5,63%	5,32%	4,81%	4,42%	4,32%	5,89%	6,68%	7,27%	8,29%	9,92%	10,04%	8,28%	7,01%
51	Ludbreg	10,66%	9,83%	8,19%	6,83%	6,13%	6,71%	7,19%	6,91%	6,83%	6,76%	5,86%	4,71%	3,62%
52	Makarska	6,09%	5,85%	5,81%	5,18%	4,33%	4,28%	4,98%	5,35%	5,34%	5,59%	5,65%	5,23%	4,35%
53	Mali Lošinj	2,93%	2,62%	3,14%	2,79%	2,48%	2,72%	3,58%	3,56%	3,44%	3,61%	3,36%	3,21%	3,17%
54	Metković	7,70%	8,25%	8,21%	7,63%	6,71%	6,93%	8,30%	8,54%	9,41%	10,64%	11,37%	11,38%	10,39%
55	Mursko Središće	6,98%	7,37%	7,04%	6,53%	6,12%	7,02%	7,79%	7,35%	7,99%	8,16%	7,24%	5,48%	4,45%

56	Našice	12,22%	12,44%	12,04%	11,65%	11,01%	12,15%	13,20%	13,25%	14,15%	14,69%	14,39%	13,11%	12,01%
57	Nin	6,71%	6,11%	5,57%	5,34%	4,80%	5,67%	5,44%	5,31%	5,33%	5,61%	5,26%	4,11%	3,59%
58	Nova Gradiška	11,16%	11,09%	11,18%	10,18%	9,65%	10,24%	11,68%	11,61%	12,02%	12,82%	12,90%	11,47%	10,05%
59	Novalja	5,34%	4,97%	5,00%	4,66%	4,29%	4,38%	4,82%	3,91%	4,00%	4,38%	4,72%	3,56%	2,85%
60	Novi Marof	4,29%	4,54%	3,66%	2,95%	2,59%	3,54%	4,88%	4,85%	4,81%	5,07%	4,15%	3,45%	2,50%
61	Novi Vinodolski	7,01%	6,28%	6,00%	5,07%	3,39%	3,81%	4,57%	4,35%	4,63%	5,09%	5,61%	4,77%	3,85%
62	Novigrad-Cittanova	1,44%	1,72%	1,54%	1,43%	1,29%	1,59%	2,01%	2,48%	2,98%	3,29%	2,96%	2,34%	2,04%
63	Novska	7,37%	7,72%	7,13%	6,46%	7,19%	8,59%	9,50%	9,55%	11,12%	11,78%	12,34%	12,02%	11,46%
64	Obrovac	14,75%	12,23%	11,51%	9,73%	9,09%	9,65%	9,33%	9,76%	11,04%	11,69%	10,28%	8,53%	7,60%
65	Ogulin	6,14%	7,40%	6,68%	6,40%	5,72%	6,67%	7,19%	7,10%	7,52%	7,81%	7,87%	7,66%	6,88%
66	Omiš	11,55%	9,93%	9,28%	8,88%	8,01%	8,64%	9,48%	9,83%	9,85%	10,06%	9,14%	8,01%	6,82%
67	Opatija	4,23%	4,42%	4,17%	3,72%	3,25%	3,73%	4,87%	4,86%	5,12%	5,35%	5,10%	4,73%	4,17%
68	Opuzen	9,25%	9,87%	9,64%	8,95%	7,87%	7,53%	7,96%	7,84%	7,82%	8,24%	8,93%	9,23%	9,18%
69	Orahovica	10,33%	9,42%	9,64%	8,65%	7,39%	6,94%	8,48%	8,63%	9,52%	10,03%	10,66%	9,48%	8,29%
70	Oroslavje	4,77%	5,28%	4,77%	3,61%	3,09%	4,56%	5,72%	6,14%	6,48%	6,90%	6,72%	5,78%	4,46%
71	Osijek	8,19%	8,01%	7,38%	6,58%	5,91%	6,67%	8,01%	8,05%	8,49%	9,21%	9,20%	8,27%	7,16%
72	Otočac	5,54%	6,72%	6,99%	6,32%	5,67%	5,94%	6,51%	6,35%	6,64%	7,26%	7,60%	7,72%	6,75%
73	Otok	10,12%	9,92%	9,33%	8,92%	8,51%	9,39%	10,10%	11,25%	12,58%	13,94%	13,71%	12,37%	10,79%
74	Ozalj	9,42%	9,19%	9,02%	8,52%	7,80%	8,72%	9,91%	9,33%	9,31%	8,74%	7,16%	6,10%	4,37%
75	Pag	5,03%	4,99%	5,13%	4,84%	4,68%	5,21%	5,13%	5,03%	4,57%	4,19%	3,79%	3,11%	2,99%
76	Pakrac	8,30%	7,71%	6,98%	6,18%	5,58%	6,55%	7,08%	7,38%	8,92%	9,92%	9,75%	8,68%	7,34%
77	Pazin	3,73%	3,91%	3,52%	3,13%	2,96%	3,75%	4,32%	4,26%	4,52%	4,49%	3,90%	3,03%	2,40%
78	Petrinja	13,15%	13,14%	12,48%	11,45%	10,53%	11,07%	12,30%	12,29%	13,29%	14,06%	13,56%	12,35%	10,96%
79	Pleternica	6,74%	7,08%	7,29%	6,82%	6,45%	7,23%	8,00%	8,34%	9,28%	9,97%	9,12%	7,82%	6,68%
80	Ploče	9,52%	9,27%	8,84%	7,39%	5,91%	6,51%	6,72%	6,78%	7,02%	7,86%	8,49%	8,23%	7,46%
81	Poreč	2,89%	2,98%	2,76%	2,55%	2,29%	2,89%	3,39%	3,31%	3,15%	3,45%	3,25%	2,59%	2,13%
82	Požega	6,33%	6,49%	6,38%	6,31%	5,80%	6,55%	7,19%	7,51%	7,86%	8,39%	7,76%	6,66%	5,69%
83	Pregrada	3,94%	4,12%	3,81%	3,51%	3,00%	4,44%	6,34%	6,64%	7,26%	7,30%	6,77%	5,76%	4,08%
84	Prelog	4,38%	4,43%	3,86%	3,14%	2,82%	3,53%	4,62%	5,07%	5,51%	5,14%	4,37%	3,57%	3,27%

85	Pula	3,77%	3,80%	3,54%	3,36%	3,01%	3,79%	4,65%	4,76%	4,96%	5,70%	4,91%	4,12%	3,32%
86	Rab	4,81%	5,03%	5,46%	5,45%	4,90%	4,73%	5,21%	5,18%	5,13%	5,26%	4,66%	3,91%	3,37%
87	Rijeka	6,76%	6,76%	6,16%	5,50%	5,03%	5,76%	6,94%	7,05%	7,39%	7,75%	7,40%	6,11%	5,03%
88	Rovinj	2,40%	2,71%	3,09%	3,12%	3,23%	3,59%	3,54%	3,56%	3,55%	3,51%	2,98%	2,74%	2,18%
89	Samobor	4,62%	4,25%	3,79%	3,23%	2,74%	3,49%	4,49%	4,48%	5,01%	5,54%	5,59%	5,21%	4,13%
90	Senj	8,59%	8,00%	8,23%	7,75%	6,75%	7,42%	8,38%	8,24%	8,05%	8,09%	8,50%	8,49%	7,89%
91	Sinj	9,47%	8,99%	8,40%	7,77%	6,74%	7,30%	9,14%	9,78%	10,96%	11,70%	11,58%	10,38%	9,06%
92	Sisak	10,52%	10,10%	9,45%	8,61%	8,05%	8,82%	9,71%	9,69%	11,39%	11,73%	11,74%	10,67%	9,65%
93	Skradin	10,37%	9,75%	8,70%	8,11%	6,79%	7,06%	7,44%	7,19%	7,83%	8,24%	7,93%	7,27%	7,24%
94	Slatina	11,84%	11,94%	11,59%	10,90%	10,06%	11,59%	13,00%	13,05%	14,30%	14,95%	13,80%	12,57%	11,35%
95	Slavonski Brod	9,37%	9,29%	8,78%	8,04%	6,87%	7,71%	9,06%	9,45%	9,59%	9,94%	8,45%	6,60%	5,61%
96	Slunj	10,79%	11,97%	11,78%	11,28%	10,19%	11,89%	12,76%	12,62%	12,76%	13,19%	13,49%	12,69%	11,35%
97	Solin	8,48%	8,08%	7,64%	7,00%	6,27%	7,15%	7,90%	8,09%	8,75%	9,44%	8,85%	7,82%	6,75%
98	Split	9,39%	9,10%	8,51%	7,88%	7,14%	7,44%	8,42%	8,99%	9,77%	10,23%	9,98%	9,30%	8,27%
99	Stari Grad	5,85%	5,38%	5,41%	4,56%	4,29%	4,48%	4,77%	4,48%	4,53%	4,81%	4,28%	3,79%	4,20%
100	Supetar	4,50%	4,16%	4,33%	4,16%	3,48%	3,77%	4,57%	4,48%	4,93%	5,26%	4,90%	4,41%	3,69%
101	Sveta Nedelja	4,20%	4,08%	3,75%	3,11%	2,64%	3,66%	4,75%	4,62%	4,79%	5,33%	5,29%	5,04%	3,92%
102	Sveti Ivan Zelina	3,21%	3,24%	2,80%	2,21%	1,85%	2,35%	3,40%	3,74%	4,33%	4,86%	4,55%	4,01%	3,05%
103	Šibenik	8,48%	7,53%	6,60%	5,78%	4,95%	5,41%	5,93%	5,74%	6,05%	6,31%	6,09%	5,69%	5,53%
104	Trilj	10,83%	10,08%	9,51%	9,13%	8,19%	8,96%	10,21%	11,25%	12,64%	13,47%	13,19%	11,65%	10,14%
105	Trogir	10,08%	9,10%	8,78%	8,12%	6,80%	7,62%	8,71%	8,49%	9,34%	9,83%	9,49%	7,98%	6,81%
106	Umag	1,90%	2,21%	2,24%	1,87%	1,63%	2,39%	3,06%	2,95%	3,55%	4,09%	4,15%	3,20%	2,54%
107	Valpovo	9,35%	9,19%	8,75%	8,88%	8,79%	9,97%	11,03%	11,05%	11,50%	12,83%	13,17%	11,85%	10,55%
108	Varaždin	5,28%	5,27%	4,79%	4,29%	3,61%	4,32%	5,16%	5,36%	5,86%	6,25%	5,45%	4,23%	3,32%
109	Varaždinske Toplice	4,04%	4,11%	3,35%	2,40%	1,96%	2,58%	3,26%	2,91%	3,16%	3,33%	2,88%	1,86%	1,63%
110	Velika Gorica	3,50%	3,52%	3,30%	2,75%	2,38%	2,81%	3,71%	4,07%	4,75%	5,43%	5,09%	3,93%	2,96%
111	Vinkovci	8,61%	8,44%	7,72%	7,43%	6,83%	7,53%	8,39%	8,41%	8,97%	9,69%	9,13%	7,83%	6,67%
112	Virovitica	9,81%	10,03%	9,44%	8,19%	7,65%	8,36%	9,45%	9,51%	10,32%	10,52%	10,34%	9,66%	8,55%
113	Vis	7,70%	6,73%	6,18%	5,75%	5,89%	6,14%	7,25%	7,91%	8,27%	8,16%	8,26%	8,45%	8,23%

114	Vodice	10,63%	9,45%	8,05%	7,04%	6,36%	7,31%	7,97%	7,86%	8,06%	8,66%	7,62%	7,31%	6,64%
115	Vodnjan	3,64%	3,83%	3,79%	3,73%	3,47%	4,22%	5,16%	4,84%	4,81%	5,58%	4,33%	3,77%	2,85%
116	Vrbovec	5,57%	5,56%	5,54%	5,19%	4,47%	5,14%	6,22%	6,12%	6,13%	6,86%	5,86%	4,55%	3,53%
117	Vrbovsko	5,52%	6,04%	5,76%	5,80%	6,26%	9,91%	11,34%	10,44%	10,43%	10,60%	10,85%	10,53%	9,49%
118	Vrgorac	9,83%	10,69%	10,55%	10,25%	9,37%	9,56%	9,49%	9,83%	10,50%	12,05%	12,62%	11,11%	10,51%
119	Vrlika	6,31%	5,96%	5,50%	4,97%	4,23%	4,41%	5,47%	5,63%	6,51%	7,47%	7,79%	6,11%	5,43%
120	Vukovar	11,69%	11,50%	10,92%	10,38%	9,69%	9,80%	10,48%	9,55%	10,20%	11,08%	10,99%	9,53%	8,11%
121	Zabok	4,09%	3,99%	3,75%	2,98%	2,28%	2,89%	4,19%	4,86%	5,46%	6,09%	5,56%	4,65%	3,71%
122	Zadar	7,35%	6,98%	6,44%	6,07%	5,46%	5,85%	6,31%	6,09%	6,20%	6,42%	5,51%	4,55%	3,93%
123	Zagreb	5,01%	5,19%	4,80%	4,01%	3,39%	3,84%	4,78%	5,01%	5,29%	5,76%	5,50%	4,89%	4,08%
124	Zaprešić	4,27%	4,15%	3,86%	3,12%	2,71%	3,30%	4,30%	4,34%	4,81%	5,54%	5,20%	4,54%	3,67%
125	Zlatar	2,33%	2,72%	2,68%	2,08%	2,29%	3,34%	4,03%	4,77%	5,36%	5,17%	3,87%	3,04%	2,40%
126	Županja	11,50%	11,43%	10,91%	10,53%	10,44%	11,75%	12,77%	12,96%	13,72%	14,48%	13,38%	10,93%	9,63%

Izvor: Nezaposlenost stanovništva prikazuje koliko je udio stanovništva u pojedinom gradu u promatranoj godini bio nezaposlen. Hrvatski zavod za zapošljavanje.

Prilog 6 Vrijednost nekretnina po stanovniku u gradovima

Rbr	Ime grada	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016
1	Bakar	3.328	6.011	6.742	7.236	7.655	10.716	10.893	26.496	49.495	50.042	50.449	51.543	52.489
2	Beli Manastir	274	376	385	398	2.630	3.134	3.151	5.587	5.745	6.249	6.847	7.213	8.074
3	Belišće	2.200	2.205	2.237	2.302	2.570	2.929	2.962	4.144	4.155	4.150	7.289	7.320	7.689
4	Benkovac	312	203	230	311	366	658	484	483	546	593	791	835	871
5	Biograd na Moru	3.330	3.439	3.352	3.279	3.767	3.808	5.337	9.639	10.166	10.733	11.735	12.260	12.848
6	Bjelovar	3.203	3.682	3.746	4.176	4.276	4.448	4.517	4.810	5.095	5.301	5.413	5.481	5.603
7	Buje	4.402	4.303	4.570	7.204	8.995	9.155	9.550	13.906	14.330	14.665	14.909	15.310	15.516
8	Buzet	1.259	1.416	1.945	2.010	2.620	2.902	2.969	3.084	3.125	3.528	4.728	33.121	33.257
9	Cres	3.222	3.353	9.799	10.983	11.237	11.880	14.146	20.871	20.876	20.682	20.768	21.143	22.115
10	Crikvenica	106.326	104.648	102.788	104.564	104.314	104.981	104.173	105.472	117.329	25.189	25.089	25.652	26.239
11	Čabar	13.698	14.051	14.367	11.694	14.698	14.797	14.981	15.288	15.906	16.071	17.329	17.744	18.320
12	Čakovec	3.284	3.598	3.609	3.607	3.678	3.945	4.267	4.892	5.460	5.443	5.646	5.711	6.136
13	Čazma	1.300	1.999	2.012	2.028	2.065	2.106	2.053	2.093	2.116	2.156	2.198	2.475	2.682
14	Daruvar	2.207	2.355	2.619	2.694	2.943	3.138	3.323	4.490	4.492	7.800	7.916	8.593	8.804
15	Delnice	4.292	4.310	4.687	39.089	41.909	20.455	20.676	21.245	21.391	21.857	23.255	24.122	34.216
16	Donja Stubica	1.067	1.031	5.179	5.603	5.279	5.170	5.154	5.056	4.999	5.023	4.959	4.821	7.474
17	Donji Miholjac	14.738	14.160	14.277	14.352	14.554	15.548	15.676	15.831	15.779	15.788	15.938	16.181	16.481
18	Drniš	760	2.781	1.332	1.454	1.805	1.933	2.099	2.182	2.231	2.327	2.412	2.514	1.869
19	Dubrovnik	30.086	28.900	28.598	28.378	28.064	28.003	28.257	122.988	120.120	118.708	119.015	122.075	121.496
20	Duga Resa	1.724	1.819	1.840	1.979	1.833	1.772	1.753	1.798	1.981	1.916	1.409	1.489	1.814
21	Dugo Selo	2.795	3.269	3.481	3.195	3.824	4.340	4.600	5.543	5.230	4.780	4.828	5.376	6.288
22	Đakovo	5.695	5.745	5.786	6.004	6.061	6.097	6.258	6.303	6.437	6.555	6.636	7.372	7.928
23	Đurđevac	6.612	6.563	7.232	7.225	7.302	7.260	7.350	8.011	8.052	7.826	8.443	9.034	8.705
24	Garešnica	3.482	3.447	3.535	3.592	5.603	5.920	6.481	6.567	6.865	7.027	7.274	7.502	7.760
25	Glina	3.024	3.239	4.634	4.688	5.130	5.267	6.220	6.650	7.480	7.920	8.202	8.697	9.122
26	Gospić	2.440	3.021	6.029	6.663	7.317	7.586	7.830	8.109	8.648	8.685	9.095	15.127	15.201

27	Grubišno Polje	2.095	2.095	2.272	2.481	3.181	3.555	3.560	6.516	6.692	7.246	7.366	7.650	8.368
28	Hrvatska Kostajnica	2.045	2.074	4.752	4.035	4.338	3.988	5.029	5.202	5.383	6.102	6.100	5.669	5.781
29	Hvar	4.876	4.948	5.029	5.759	7.833	8.235	6.527	5.301	5.289	5.483	5.867	5.697	6.178
30	Ilok	771	795	846	800	886	999	4.528	4.739	5.078	5.168	6.578	5.490	5.653
31	Imotski	732	703	1.074	1.119	1.644	1.863	2.542	2.971	3.259	3.312	3.315	3.297	3.419
32	Ivanec	1.157	1.105	1.100	1.319	1.361	1.390	1.431	1.457	1.447	1.460	4.747	5.093	5.297
33	Ivanić-Grad	2.668	2.719	3.517	3.973	4.071	4.100	4.104	4.202	4.272	5.356	5.421	5.532	5.631
34	Jastrebarsko	3.243	3.288	3.354	3.285	3.794	4.059	4.150	4.797	4.904	5.515	6.410	5.691	5.951
35	Karlovac	1.985	1.835	2.013	2.057	2.232	2.892	3.042	2.920	4.191	7.884	8.502	5.112	7.629
36	Kastav	3.241	3.325	3.495	3.653	3.896	3.988	4.361	8.185	28.087	27.817	27.939	28.046	29.753
37	Kaštela	753	992	1.358	1.448	1.730	1.756	1.760	1.943	2.011	2.358	2.360	2.385	2.952
38	Klanjec	484	497	539	743	747	754	790	872	844	1.026	1.148	1.436	1.545
39	Knin	338	395	405	4.252	4.343	1.821	2.661	2.982	3.056	3.103	3.197	3.349	4.016
40	Komiža	2.617	2.847	2.845	2.840	3.797	15.680	16.119	16.297	17.662	23.619	23.955	25.312	26.044
41	Koprivnica	3.409	3.395	3.416	3.743	5.490	5.626	5.842	7.876	9.002	9.577	10.548	10.533	10.694
42	Korčula	7.483	8.650	8.780	8.910	20.712	21.279	21.295	21.500	21.492	21.726	23.860	24.128	24.648
43	Kraljevica	4.980	4.730	4.706	6.227	39.288	39.479	39.682	39.681	39.938	39.788	40.263	44.335	45.713
44	Krapina	2.035	2.395	2.483	3.083	3.129	3.173	3.188	3.287	3.309	3.318	3.281	3.207	3.264
45	Križevci	9.703	9.699	10.006	13.629	12.776	12.873	12.847	13.144	8.218	8.785	8.515	9.230	10.320
46	Krk	6.261	9.480	6.400	6.864	7.097	11.253	11.870	12.002	12.297	14.394	18.490	18.756	18.822
47	Kutina	6.225	7.018	7.139	6.755	6.848	6.841	7.667	7.608	7.610	8.111	8.184	8.322	14.555
48	Labin	3.802	3.916	4.482	4.642	4.670	8.045	8.259	8.428	8.183	11.753	15.287	18.528	19.557
49	Lepoglava	389	572	839	1.010	1.723	2.274	2.625	2.589	2.610	2.682	2.748	2.854	2.906
50	Lipik	2.855	3.184	3.508	3.589	3.685	4.662	4.705	5.453	5.500	5.686	5.766	5.768	5.945
51	Ludbreg	11.460	11.609	13.486	13.027	13.477	13.409	13.951	12.754	8.695	9.198	25.443	26.087	29.897
52	Makarska	5.319	5.676	5.639	5.629	5.520	11.800	11.886	11.907	12.028	11.934	11.961	12.034	12.224
53	Mali Lošinj	12.409	13.520	13.926	13.093	13.866	15.605	24.873	24.685	69.168	70.508	71.916	147.826	149.099
54	Metković	1.264	1.693	2.145	2.439	2.539	2.638	2.749	923	2.146	1.127	1.151	1.514	1.541

55	Mursko Središće	2.247	2.313	2.403	2.436	2.828	3.239	3.393	3.775	3.836	3.985	4.177	4.670	5.666
56	Našice	1.003	1.031	1.216	1.456	1.540	1.650	2.137	2.390	2.465	2.263	3.552	4.497	4.748
57	Nin	94.501	91.101	88.704	62.130	60.607	60.064	59.785	59.602	58.551	58.290	58.569	58.319	59.072
58	Nova Gradiška	11.816	11.968	11.826	11.778	11.912	16.895	17.113	17.033	17.228	17.036	17.201	17.976	18.858
59	Novalja	3.087	3.472	3.784	4.091	4.802	5.415	6.110	6.640	6.965	6.585	7.441	8.016	9.443
60	Novi Marof	685	713	830	877	1.179	1.236	1.336	3.273	3.590	3.609	3.593	3.654	3.723
61	Novi Vinodolski	2.405	1.995	3.831	4.210	21.110	21.048	23.105	46.185	46.266	91.520	93.130	90.552	91.612
62	Novigrad-Cittanova	1.006	1.784	3.052	49.158	50.351	50.234	50.047	51.843	50.166	51.114	51.890	49.800	47.967
63	Novska	3.930	3.554	3.636	3.972	4.241	4.341	5.656	7.182	7.220	7.532	7.710	7.888	8.073
64	Obrovac	1.543	1.456	1.371	4.042	1.972	1.943	1.447	1.562	1.691	1.803	2.545	3.299	3.667
65	Ogulin	32.837	33.204	33.459	34.585	35.953	37.508	37.975	38.469	38.649	38.865	23.717	24.003	24.439
66	Omiš	1.798	1.806	1.892	1.904	1.867	1.933	1.943	1.954	1.952	1.867	2.103	2.208	2.540
67	Opatija	7.703	8.185	8.448	9.108	9.655	10.002	15.115	18.363	19.491	20.739	24.249	25.321	26.517
68	Opuzen	3.343	3.481	3.637	3.833	5.729	5.736	2.987	16.179	16.173	16.445	16.931	16.878	17.026
69	Orahovica	5.099	5.463	5.530	5.485	5.507	5.816	5.930	6.701	6.826	5.312	5.485	5.502	5.975
70	Oroslavje	1.031	1.025	1.109	1.471	1.475	1.514	1.530	1.574	1.594	1.685	2.203	2.283	2.553
71	Osijek	2.977	3.243	3.397	3.658	3.678	5.156	9.610	9.972	10.302	12.684	13.743	14.167	14.654
72	Otočac	624	628	660	924	2.158	2.795	3.048	3.591	4.780	4.846	4.872	5.054	5.415
73	Otok	271	274	293	541	1.226	1.323	1.263	1.276	1.340	1.397	1.445	3.155	3.453
74	Ozalj	1.608	1.698	1.714	1.842	2.334	2.426	2.578	2.829	2.858	3.115	3.222	3.348	3.472
75	Pag	5.187	5.213	5.230	5.316	5.520	5.606	5.686	5.746	5.883	5.931	6.014	6.099	6.234
76	Pakrac	8.364	8.781	9.077	9.393	9.722	10.056	11.021	11.329	11.937	13.325	13.490	14.024	14.471
77	Pazin	2.802	2.668	2.604	4.236	4.259	4.258	4.301	11.700	11.600	10.890	10.880	10.958	15.106
78	Petrinja	8.203	8.577	8.812	9.223	10.062	10.039	9.937	10.245	10.552	10.903	9.123	8.166	8.582
79	Pleternica	748	786	551	598	744	1.308	1.331	1.485	1.406	1.916	2.922	4.105	4.656
80	Ploče	567	605	609	1.704	1.789	1.820	1.842	2.505	2.783	2.801	2.889	2.928	3.062
81	Poreč	8.296	8.115	8.294	21.208	24.003	27.912	28.053	27.900	24.386	24.370	24.410	24.859	24.973
82	Požega	2.952	3.961	4.121	4.397	5.032	5.299	6.624	7.210	7.597	8.237	8.814	9.123	14.484

83	Pregrada	1.897	1.977	2.577	2.898	3.285	3.280	3.908	4.038	4.328	5.967	6.976	7.499	7.779
84	Prelog	4.166	4.429	4.674	4.877	3.882	4.548	5.246	6.445	6.726	7.353	7.502	8.414	8.512
85	Pula	4.456	6.388	6.981	7.500	49.313	48.860	49.540	54.024	58.371	58.560	54.051	226.937	155.919
86	Rab	4.721	4.758	4.902	6.379	7.062	7.474	7.188	7.252	8.419	7.522	7.968	8.126	8.413
87	Rijeka	19.277	19.522	21.361	21.352	22.218	32.963	39.293	43.421	46.092	48.559	53.360	54.824	56.770
88	Rovinj	55.398	55.259	54.356	53.106	53.431	54.082	54.372	50.735	55.157	54.886	52.423	52.374	51.814
89	Samobor	1.530	1.636	1.907	2.083	2.347	2.601	3.607	5.133	5.159	5.332	5.369	6.765	6.901
90	Senj	1.717	1.721	1.655	2.583	3.339	3.382	3.536	5.879	5.836	5.841	5.968	6.256	7.582
91	Sinj	511	512	540	539	1.032	1.069	1.090	1.084	1.011	7.987	9.183	9.217	9.261
92	Sisak	2.602	2.712	2.910	3.760	4.179	4.397	4.529	4.802	6.620	6.711	7.991	8.158	8.545
93	Skradin	540	545	563	673	847	949	1.176	1.206	1.230	1.258	2.512	2.440	2.520
94	Slatina	1.687	1.814	2.414	2.766	3.892	4.141	4.202	4.695	4.954	4.644	4.641	4.862	5.079
95	Slavonski Brod	2.151	2.245	2.760	2.753	2.762	5.909	6.652	6.800	7.034	8.278	8.882	19.901	20.859
96	Slunj	5.523	3.237	1.524	2.040	3.430	3.562	3.622	3.890	3.916	6.993	10.417	9.271	10.026
97	Solin	3.813	3.814	4.025	4.209	6.326	7.208	7.209	7.165	7.280	7.170	6.747	7.153	7.161
98	Split	2.913	3.161	3.379	4.355	11.075	17.590	19.263	15.972	16.267	16.446	17.008	18.356	20.374
99	Stari Grad	2.643	3.169	6.137	6.569	12.593	12.807	12.887	13.020	12.911	12.869	15.644	17.722	17.763
100	Supetar	149	617	2.625	2.636	2.679	4.276	15.718	8.515	8.236	8.124	8.082	8.167	8.212
101	Sveta Nedelja	953	1.383	1.582	1.766	2.115	2.229	2.257	2.578	2.637	2.671	2.750	3.883	3.915
102	Sveti Ivan Zelina	1.799	1.875	2.025	2.144	2.325	2.365	2.441	2.464	2.617	2.680	2.772	2.882	2.965
103	Šibenik	7.038	10.755	7.420	7.606	7.797	7.919	8.151	8.065	8.877	8.939	9.338	9.909	10.150
104	Trilj	341	368	0	515	735	1.172	1.350	1.357	1.371	1.396	1.528	1.544	1.559
105	Trogir	3.529	3.474	3.392	3.565	3.621	3.512	3.508	3.495	3.574	3.582	3.575	3.579	3.709
106	Umag	7.818	8.231	8.350	13.172	13.759	14.376	15.170	15.419	11.104	12.950	16.434	16.807	117.660
107	Valpovo	4.233	4.213	4.216	4.229	4.339	4.507	4.450	4.812	5.521	5.558	6.418	6.524	6.636
108	Varaždin	4.752	4.856	4.946	5.334	6.864	9.028	10.419	10.498	10.058	10.530	10.874	10.965	11.153
109	Varaždinske Toplice	694	831	868	876	1.490	2.049	2.722	2.759	2.793	2.784	2.830	3.037	3.238
110	Velika Gorica	208	236	238	283	525	569	726	1.049	1.504	1.945	1.990	3.186	3.357

111	Vinkovci	2.705	2.818	2.894	2.771	2.864	2.964	5.332	5.260	5.263	19.912	19.960	20.027	19.959
112	Virovitica	2.680	2.952	3.074	3.609	4.075	4.794	5.430	8.606	8.808	8.780	9.627	10.526	10.749
113	Vis	2.388	2.383	2.348	2.314	7.048	7.349	7.271	10.816	10.607	15.440	18.170	18.274	19.171
114	Vodice	796	2.300	5.581	6.245	6.547	6.799	6.860	7.530	8.021	8.047	8.263	9.397	9.587
115	Vodnjan	1.933	2.040	6.923	7.438	9.028	9.417	9.892	10.077	10.251	10.644	11.277	11.878	12.066
116	Vrbovec	1.901	1.986	2.008	1.917	1.104	1.100	1.112	1.362	1.972	2.127	2.436	4.736	4.801
117	Vrbovsko	2.524	2.561	2.862	3.442	6.696	7.494	7.629	7.898	8.120	8.370	8.560	5.764	6.046
118	Vrgorac	1.019	1.577	1.569	1.985	2.026	2.202	2.484	2.688	2.861	3.224	3.970	4.398	4.746
119	Vrlika	4.270	4.714	4.807	5.022	5.265	5.455	5.652	5.853	6.068	6.338	6.550	6.450	6.551
120	Vukovar	9.569	9.690	9.737	10.458	10.842	9.484	9.593	10.085	10.338	11.538	11.980	12.460	12.079
121	Zabok	1.173	1.299	1.915	2.276	2.235	2.197	3.257	3.229	3.232	3.477	3.470	3.610	3.591
122	Zadar	2.465	2.704	3.239	4.010	4.220	4.467	5.600	5.558	5.937	7.985	8.652	8.715	9.493
123	Zagreb	4.082	4.271	4.289	4.498	4.899	4.919	5.031	5.221	5.118	5.262	6.638	6.751	7.228
124	Zaprešić	2.664	2.919	3.002	3.617	3.955	4.125	4.250	6.023	8.384	8.684	8.767	8.868	9.300
125	Zlatar	1.311	1.328	1.339	1.323	1.341	1.354	1.366	1.370	1.382	1.462	1.497	1.569	2.141
126	Županja	2.912	9.156	9.185	8.974	9.300	6.846	6.821	6.931	7.135	6.887	7.046	6.540	6.880

Izvor: Ministarstvo financija i Državni zavod za statistiku

Prilog 7 Prihodi od nekretnina u gradovima

Rbr	Ime grada	2002	2003	2004	2005	2006	2007	2008	2009
1	Bakar	664.761	705.913	788.029	2.345.341	770.187	1.116.201	8.251.133	30.222.565
2	Beli Manastir	1.259.042	682.968	4.032.458	4.165.823	4.285.918	1.086.090	8.657.243	6.746.936
3	Belišće	1.818.075	1.610.763	1.752.998	1.966.417	3.088.403	2.428.220	2.245.689	1.481.357
4	Benkovac	804.916	388.350	751.119	661.490	855.175	748.958	11.254.356	2.983.583
5	Biograd na Moru	1.860.265	4.811.504	2.095.562	2.668.158	4.983.649	3.278.096	3.929.459	9.531.050
6	Bjelovar	2.746.068	2.649.259	7.228.294	6.074.972	11.594.633	5.153.234	4.759.430	5.114.854
7	Buje	4.206.299	3.152.415	6.483.413	6.334.319	7.615.279	5.544.813	10.541.279	7.051.715
8	Buzet	2.587.677	1.775.927	2.856.036	2.496.923	2.448.641	1.133.434	2.436.475	1.263.126
9	Cres	1.536.045	3.157.784	3.115.748	3.038.265	2.940.206	2.956.376	6.633.545	3.082.226
10	Crikvenica	4.641.224	5.406.880	5.083.228	4.042.606	11.753.972	5.120.863	14.271.376	5.010.613
11	Čabar	165.345	171.528	198.624	151.482	256.813	280.520	1.084.158	146.159
12	Čakovec	4.154.399	16.720.195	12.448.906	11.888.008	9.886.374	5.348.006	14.315.151	12.651.600
13	Čazma	888.385	712.771	1.303.673	1.243.208	722.470	1.254.520	1.472.861	1.407.691
14	Daruvar	1.656.344	1.877.373	2.488.292	12.085.011	3.126.142	2.544.995	2.714.353	2.106.168
15	Delnice	1.065.575	929.331	1.469.445	1.731.608	1.371.326	2.272.498	1.909.875	856.505
16	Donja Stubica	508.803	827.149	331.152	340.777	335.633	232.552	350.980	210.457
17	Donji Miholjac	2.220.200	1.692.751	2.268.108	3.822.436	4.010.939	2.918.908	1.818.157	2.385.608
18	Drniš	290.002	328.869	584.879	557.212	600.771	1.786.014	764.762	337.512
19	Dubrovnik	16.772.281	16.831.030	46.427.038	36.320.794	33.952.199	29.144.920	25.642.917	26.792.459
20	Duga Resa	877.167	874.930	969.531	1.146.906	1.630.852	1.479.602	2.845.674	2.187.755
21	Dugo Selo	892.140	846.260	822.922	825.025	2.576.205	23.340.537	10.546.799	697.494
22	Đakovo	1.575.848	1.374.080	1.584.999	1.376.110	1.406.326	1.579.310	1.425.840	1.528.288
23	Đurđevac	150.607	549.363	3.600.606	781.643	561.217	1.476.728	511.835	594.419
24	Garešnica	1.343.742	1.150.536	2.880.940	2.644.035	9.632.321	1.618.475	1.694.139	1.175.256
25	Glina	180.755	155.118	172.071	130.353	88.340	194.307	689.786	811.883
26	Gospić	1.959.659	3.427.628	1.405.462	2.249.999	2.434.206	3.075.725	1.186.268	1.339.877

27	Grubišno Polje	574.541	804.399	736.918	525.070	697.973	1.200.554	1.382.856	1.312.942
28	Hrvatska Kostajnica	75.228	174.447	301.316	614.506	1.760.970	1.850.441	1.001.982	321.007
29	Hvar	2.374.465	668.148	1.160.111	2.241.208	1.701.663	1.201.293	1.305.183	1.048.221
30	Ilok	319.647	479.287	601.876	458.746	761.003	882.038	591.576	689.045
31	Imotski	2.592.955	1.045.446	973.986	625.386	782.916	415.964	312.353	522.409
32	Ivanec	119.454	122.389	777.493	701.438	1.913.461	1.367.254	1.357.468	714.458
33	Ivanić-Grad	1.604.015	757.365	1.159.158	1.051.075	1.121.080	2.012.768	5.925.173	3.328.769
34	Jastrebarsko	6.955.764	423.689	1.124.070	379.322	1.705.216	9.634.311	3.664.327	860.345
35	Karlovac	5.010.686	9.043.938	19.832.745	22.693.732	12.133.947	36.047.770	13.899.862	15.605.492
36	Kastav	1.459.015	886.866	2.468.995	1.785.378	791.875	890.743	990.984	1.020.061
37	Kaštela	862.745	999.103	851.375	924.022	12.068.583	1.295.391	8.920.166	1.960.401
38	Klanjec	266.303	292.200	270.499	280.435	302.174	258.169	259.887	258.161
39	Knin	1.355.222	1.392.054	1.459.494	1.279.492	1.533.515	1.620.369	3.616.463	2.491.936
40	Komiža	141.259	63.440	1.106.360	55.105	164.581	74.191	60.296	92.560
41	Koprivnica	2.518.280	3.180.693	7.810.535	47.426.799	17.580.392	58.781.596	5.968.855	6.951.979
42	Korčula	2.138.740	2.009.955	4.310.525	2.931.423	2.918.499	2.614.406	4.153.426	4.603.258
43	Kraljevica	2.925.794	3.923.545	855.086	3.685.798	1.914.981	5.519.312	1.057.352	865.605
44	Krapina	953.498	1.455.239	553.726	1.006.363	2.071.449	5.922.568	1.482.745	3.544.308
45	Križevci	1.773.734	1.660.876	5.323.206	1.720.372	3.640.351	2.843.946	5.371.134	2.143.469
46	Krk	3.391.784	2.373.482	5.241.934	3.776.569	3.384.509	2.627.626	4.477.610	8.725.919
47	Kutina	2.312.964	5.269.641	2.151.888	2.776.163	8.603.165	5.216.635	3.555.886	9.331.433
48	Labin	4.665.499	5.172.437	4.695.717	12.590.231	4.388.774	5.410.855	4.451.133	6.339.828
49	Lepoglava	42.961	66.839	54.289	86.485	169.327	52.162	48.288	83.410
50	Lipik	169.325	167.001	202.630	691.277	1.164.577	1.104.078	1.529.770	1.400.667
51	Ludbreg	630.256	1.377.704	1.447.869	1.099.811	1.722.412	4.478.401	1.109.086	691.281
52	Makarska	2.751.650	3.923.313	2.394.647	1.903.815	2.891.319	5.506.217	7.414.726	3.003.624
53	Mali Lošinj	4.114.387	4.857.943	4.815.749	4.062.477	11.430.464	9.647.063	13.768.549	10.358.532
54	Metković	1.057.691	844.459	386.189	496.404	1.940.186	592.352	403.908	629.933

55	Mursko Središće	543.770	892.535	418.038	420.006	484.946	478.613	263.095	212.704
56	Našice	951.247	883.130	4.975.575	3.879.857	2.329.253	1.748.824	7.861.167	2.359.684
57	Nin	1.032.998	845.598	2.654.017	2.673.215	1.209.963	1.721.040	2.913.485	715.182
58	Nova Gradiška	2.100.756	4.520.179	2.505.372	3.804.568	3.514.617	4.111.852	4.700.314	9.128.286
59	Novalja	2.601.133	2.514.212	2.360.584	1.936.314	4.100.848	7.893.123	4.715.936	3.153.137
60	Novi Marof	88.924	84.557	160.817	449.901	286.646	876.118	397.624	243.438
61	Novi Vinodolski	1.404.198	2.758.513	2.002.984	3.075.322	4.649.710	2.165.660	10.092.626	13.592.328
62	Novigrad-Cittanova	3.203.679	7.258.917	7.967.333	8.122.139	9.336.986	9.773.674	13.317.771	10.453.373
63	Novska	492.826	276.409	233.368	1.051.196	783.173	977.716	1.291.174	904.642
64	Obrovac	134.722	4.347.302	379.192	373.434	867.841	2.457.629	9.097.572	418.317
65	Ogulin	855.171	828.881	2.708.611	1.732.795	1.226.541	910.442	1.695.980	1.538.392
66	Omiš	10.374.769	12.429.110	37.517.131	4.864.781	19.572.486	4.101.336	16.451.057	3.988.817
67	Opatija	15.061.364	24.473.447	10.408.545	10.695.756	17.652.014	15.909.958	14.388.597	29.771.268
68	Opuzen	403.581	522.795	3.381.043	3.463.464	1.384.452	731.819	607.512	725.216
69	Orahovica	704.325	922.219	644.873	1.166.736	846.909	1.325.283	1.328.126	955.954
70	Oroslavje	132.279	109.642	154.156	133.490	134.119	278.162	189.622	434.066
71	Osijek	40.390.535	36.864.008	35.766.295	48.600.521	52.729.928	56.043.564	62.598.965	31.833.520
72	Otočac	242.442	626.392	421.759	1.077.078	2.098.880	3.243.831	1.316.121	329.534
73	Otok	447.621	403.619	830.950	3.074.003	696.834	517.166	829.861	730.954
74	Ozalj	1.515.990	520.916	3.030.813	814.690	1.435.069	258.676	431.892	209.882
75	Pag	14.001.327	34.924.052	1.002.985	836.232	4.393.347	2.761.581	978.657	8.680.123
76	Pakrac	399.552	835.056	635.739	1.107.672	1.739.011	1.044.852	595.712	650.072
77	Pazin	5.040.699	4.717.464	5.041.647	7.805.018	6.149.031	7.064.455	6.108.871	5.786.914
78	Petrinja	864.951	49.336	783.538	809.116	723.620	460.886	362.223	505.773
79	Pleternica	620.222	842.161	187.035	343.537	1.097.185	739.413	478.377	643.097
80	Ploče	2.173.739	2.585.939	8.305.874	1.852.930	7.669.770	2.402.615	1.525.521	1.814.830
81	Poreč	5.720.551	8.736.325	13.741.390	55.698.043	13.683.029	19.763.103	89.905.277	57.787.997
82	Požega	2.677.001	5.313.552	2.101.889	11.419.506	3.949.045	2.375.413	1.953.048	2.385.283

83	Pregrada	209.874	190.799	98.949	494.484	1.370.938	909.667	280.321	91.977
84	Prelog	1.093.684	384.982	2.705.921	1.569.249	6.596.875	7.655.552	6.545.279	2.123.495
85	Pula	44.688.501	52.338.368	71.317.966	59.480.722	69.431.701	56.929.187	51.900.538	59.091.096
86	Rab	4.618.905	876.675	667.688	699.485	706.164	630.623	593.672	708.987
87	Rijeka	119.276.421	153.234.142	107.497.294	111.883.527	128.881.335	132.396.692	137.700.818	130.464.161
88	Rovinj	8.721.470	11.461.731	9.626.210	9.240.351	21.855.347	24.154.807	11.270.152	22.493.150
89	Samobor	5.366.129	8.802.563	6.990.621	6.634.306	18.833.915	26.856.661	4.169.258	7.885.548
90	Senj	6.890.282	6.827.187	7.187.534	1.949.944	1.984.421	6.006.695	4.234.704	2.133.897
91	Sinj	1.253.166	3.050.907	2.490.902	24.031.938	426.892	827.296	889.274	1.618.633
92	Sisak	4.380.583	5.413.826	7.821.643	11.434.406	54.924.066	12.582.442	22.556.437	5.508.743
93	Skradin	671.921	239.277	312.510	293.009	730.790	1.155.855	565.796	389.711
94	Slatina	3.065.451	3.657.275	3.592.512	3.397.690	9.424.801	5.950.361	2.498.096	6.687.353
95	Slavonski Brod	6.985.704	6.858.586	15.326.885	5.413.496	18.819.906	19.347.749	13.127.870	26.708.738
96	Slunj	362.423	400.080	481.766	860.867	3.030.102	625.767	1.631.647	924.417
97	Solin	1.936.300	4.184.911	3.805.664	2.686.134	2.720.364	6.396.473	10.606.449	9.046.779
98	Split	94.937.592	118.221.312	83.000.272	80.543.165	61.450.118	61.759.781	66.182.362	79.405.242
99	Stari Grad	99.321	0	431.123	152.367	297.976	434.659	484.761	439.624
100	Supetar	1.510.898	1.837.024	1.688.110	1.589.470	1.932.230	1.672.397	1.939.912	1.858.059
101	Sveta Nedelja	304.746	591.545	512.776	358.773	372.328	231.451	184.948	412.041
102	Sveti Ivan Zelina	575.346	408.682	351.011	455.202	420.225	1.232.318	1.093.849	1.443.391
103	Šibenik	21.708.000	10.544.491	8.811.622	17.325.831	17.166.163	18.846.349	13.178.745	10.052.056
104	Trilj	134.693	445.202	98.495	122.264	951.496	3.359.679	2.671.986	472.091
105	Trogir	3.334.364	2.555.402	4.711.645	5.072.750	4.888.292	16.177.285	20.701.323	14.302.116
106	Umag	8.917.246	9.035.051	8.356.740	7.912.887	6.546.596	20.114.695	9.283.561	12.748.766
107	Valpovo	2.199.381	1.007.546	2.817.537	4.031.656	6.702.879	3.039.678	6.050.313	3.389.423
108	Varaždin	9.117.966	29.390.633	20.441.107	18.834.190	15.262.693	79.411.432	40.690.662	40.887.812
109	Varaždinske Topl	351.827	538.384	987.014	82.211	77.952	118.471	96.043	185.606
110	Velika Gorica	2.110.439	1.987.851	34.146.371	2.274.301	2.475.602	5.923.145	11.362.139	5.850.481
111	Vinkovci	2.398.614	3.861.501	4.579.371	8.378.322	7.204.009	18.085.531	12.186.149	7.573.812

112	Virovitica	2.225.466	2.315.076	1.966.168	4.191.964	9.049.660	5.753.394	5.444.848	2.823.589
113	Vis	375.676	1.743.718	465.505	906.982	442.503	479.993	999.259	470.787
114	Vodice	158.668	578.173	232.709	283.942	102.440	135.361	165.771	351.148
115	Vodnjan	8.489.994	5.073.193	12.766.522	18.495.586	21.845.851	13.924.060	10.883.278	12.528.405
116	Vrbovec	530.526	1.140.851	889.217	432.361	852.617	2.753.470	1.403.182	1.121.421
117	Vrbovsko	644.009	611.519	592.063	599.974	568.825	1.055.807	994.690	517.215
118	Vrgorac	74.072	549.816	95.640	115.064	141.460	72.084	86.698	137.373
119	Vrlika	252.301	126.781	152.957	376.325	1.056.464	581.607	199.136	140.820
120	Vukovar	500.467	1.231.667	1.361.002	1.356.117	1.208.401	3.377.093	6.125.028	10.639.570
121	Zabok	267.687	440.722	229.668	260.118	300.276	255.695	2.256.106	3.912.797
122	Zadar	36.554.183	35.066.728	37.502.141	54.203.602	34.034.060	31.789.430	65.896.775	37.422.565
123	Zagreb	311.053.851	255.988.808	323.991.212	194.511.443	214.957.587	543.247.671	474.108.292	199.911.394
124	Zaprešić	3.718.081	4.139.136	1.779.485	23.874.468	10.801.456	15.962.423	1.376.330	1.585.784
125	Zlatar	17.823	26.841	14.959	22.959	38.322	270.239	16.692	25.558
126	Županja	1.928.188	647.901	1.846.855	1.899.345	7.972.115	8.281.581	7.886.935	12.233.237
Rbr	Ime grada	2010	2011	2012	2013	2014	2015	2016	2017
1	Bakar	7.345.023	4.966.648	11.522.129	7.850.436	1.414.339	1.142.216	1.246.283	3.719.686
2	Beli Manastir	2.885.460	3.046.825	2.366.604	1.777.489	1.732.899	3.475.725	1.595.650	1.996.492
3	Belišće	1.751.839	1.503.780	1.584.034	2.364.343	9.389.364	3.949.432	2.954.884	2.484.400
4	Benkovac	5.576.819	2.846.912	1.208.358	1.350.239	1.672.423	1.142.076	731.874	2.004.599
5	Biograd na Moru	12.135.733	5.424.736	5.173.444	3.990.471	12.414.047	4.723.041	8.126.700	6.425.732
6	Bjelovar	5.254.527	6.358.049	3.923.139	2.061.218	3.107.515	2.850.232	2.347.619	3.430.965
7	Buje	4.809.948	5.029.180	5.664.814	4.649.257	5.514.502	5.340.127	6.412.832	4.174.965
8	Buzet	2.075.650	1.302.706	2.029.511	1.416.882	1.256.764	1.181.487	1.023.110	1.432.627
9	Cres	2.927.925	2.459.695	1.939.198	4.641.078	3.434.525	3.315.963	3.201.993	2.180.185
10	Crikvenica	6.742.118	5.193.968	10.536.418	7.161.822	6.722.755	7.944.684	7.129.853	7.958.562
11	Čabar	362.915	96.044	164.581	152.711	133.661	542.019	412.660	216.345
12	Čakovec	9.360.904	8.939.685	2.671.795	8.322.228	5.760.329	3.441.842	3.453.757	8.270.627
13	Čazma	1.609.561	1.223.949	1.458.658	1.581.393	1.444.593	1.263.903	877.585	1.428.744

14	Daruvar	1.882.980	2.589.154	2.341.176	4.367.038	777.909	1.613.549	1.051.421	1.328.011
15	Delnice	939.647	1.415.915	1.018.954	790.157	545.767	503.357	2.445.272	591.072
16	Donja Stubica	202.793	387.688	209.324	236.595	190.063	185.932	168.565	334.868
17	Donji Miholjac	2.430.841	2.394.034	4.067.649	3.540.194	3.779.758	2.641.405	2.494.330	2.841.733
18	Drniš	803.780	247.690	202.030	347.528	172.873	257.623	225.911	384.422
19	Dubrovnik	25.147.537	34.013.809	38.419.324	35.731.691	47.439.775	41.046.629	46.208.238	46.454.140
20	Duga Resa	1.408.346	1.539.478	1.158.968	1.229.972	1.532.126	1.231.164	519.746	769.056
21	Dugo Selo	6.992.223	695.301	5.733.397	1.209.002	743.709	1.149.663	4.274.882	901.812
22	Đakovo	1.732.861	2.384.548	2.659.192	2.666.606	2.162.462	2.474.328	2.695.062	2.413.156
23	Đurđevac	456.630	529.121	2.219.049	373.796	280.379	726.568	3.875.809	500.537
24	Garešnica	1.816.257	1.736.616	1.747.245	1.949.098	1.618.694	3.077.458	1.794.681	2.160.741
25	Glina	139.767	359.286	105.659	334.184	1.821.518	296.347	218.387	408.736
26	Gospić	1.596.626	2.423.562	941.452	1.337.136	559.836	1.072.516	705.409	917.201
27	Grubišno Polje	1.215.370	1.358.279	1.286.631	1.357.384	1.224.311	1.512.267	2.279.141	2.542.296
28	Hrvatska Kostajnica	271.656	325.426	191.876	208.566	261.845	238.560	266.674	180.940
29	Hvar	1.295.665	1.111.662	1.310.671	1.301.086	1.403.282	1.999.464	2.018.809	1.711.305
30	Ilok	789.981	1.141.882	699.956	1.082.321	1.033.136	1.971.180	2.541.456	1.785.179
31	Imotski	314.204	487.052	832.432	666.532	326.081	247.752	220.044	447.424
32	Ivanec	851.866	557.720	72.530	514.385	677.440	581.683	160.231	410.152
33	Ivanić-Grad	1.933.428	3.145.283	1.685.365	1.549.261	3.015.281	3.199.006	3.218.557	2.215.721
34	Jastrebarsko	1.127.986	838.850	1.036.822	1.239.907	855.826	589.362	942.585	653.531
35	Karlovac	13.667.917	8.923.617	8.808.303	8.860.357	8.266.901	7.296.851	10.458.433	8.873.736
36	Kastav	1.138.278	1.740.793	7.599.280	1.783.282	1.445.297	2.227.191	8.529.484	8.906.522
37	Kaštela	2.338.087	1.862.857	2.126.263	6.967.115	1.891.785	1.957.490	2.213.804	2.266.629
38	Klanjec	221.114	222.183	205.521	215.455	196.417	434.190	173.941	231.779
39	Knin	3.552.105	3.399.032	3.437.776	2.456.813	2.787.154	2.528.971	2.570.635	2.383.268
40	Komiža	103.859	130.107	116.092	119.377	98.309	299.983	170.521	310.402
41	Koprivnica	3.685.133	6.123.387	5.643.484	3.519.639	1.966.699	4.577.144	3.531.822	5.234.624

42	Korčula	2.635.404	3.001.281	3.278.513	3.264.558	8.209.605	4.010.800	4.049.220	4.808.816
43	Kraljevica	859.593	1.604.685	1.110.078	809.390	945.422	1.695.735	961.043	921.307
44	Krapina	926.658	624.135	491.721	463.493	663.440	1.017.238	755.315	1.056.124
45	Križevci	3.535.451	4.555.236	1.433.650	2.119.975	1.677.389	1.769.962	2.570.206	2.436.656
46	Krk	4.871.603	5.399.621	5.364.253	4.723.509	6.373.239	8.083.276	5.662.039	5.062.530
47	Kutina	5.498.146	3.610.133	2.771.256	1.886.807	3.413.536	3.260.965	2.354.650	2.972.089
48	Labin	5.388.128	5.949.450	7.764.082	4.691.124	6.526.835	4.985.237	5.795.568	7.250.731
49	Lepoglava	7.465	1.574.858	275.720	21.887	14.803	24.424	18.998	25.444
50	Lipik	1.266.728	1.004.177	1.391.041	1.315.898	1.794.341	4.137.367	2.171.492	1.376.178
51	Ludbreg	814.260	1.515.230	789.285	1.771.071	460.007	1.091.372	3.508.217	1.042.283
52	Makarska	6.409.278	4.384.708	4.092.425	3.367.370	2.938.607	3.385.776	4.811.278	3.276.255
53	Mali Lošinj	12.134.016	17.226.538	18.422.053	17.065.465	10.904.075	34.118.631	11.444.945	7.988.254
54	Metković	202.368	137.832	283.862	268.816	222.876	1.853.400	231.024	177.491
55	Mursko Središće	171.041	214.795	914.951	688.248	796.710	981.389	431.974	369.268
56	Našice	3.226.248	1.012.382	1.560.818	1.705.776	2.198.156	1.353.062	1.483.393	1.735.232
57	Nin	3.673.282	1.446.766	1.169.410	880.741	1.001.018	733.318	1.771.768	11.333.784
58	Nova Gradiška	3.739.448	2.999.013	5.425.266	3.398.591	5.431.513	2.738.388	2.448.745	2.808.330
59	Novalja	3.465.652	6.032.223	3.932.573	3.090.905	6.058.590	3.114.887	4.253.570	3.547.878
60	Novi Marof	449.352	331.814	419.219	862.411	465.856	263.553	908.568	606.757
61	Novi Vinodolski	2.162.983	2.223.261	3.831.291	12.604.220	3.729.371	3.379.365	4.226.869	6.358.400
62	Novigrad-Cittanova	7.051.064	25.095.209	12.649.619	10.653.634	6.326.982	4.839.352	7.382.933	4.038.092
63	Novska	1.387.880	1.199.984	1.276.092	1.547.513	1.775.328	2.459.944	2.731.234	3.368.940
64	Obrovac	539.073	675.737	1.193.149	468.599	3.235.803	2.146.011	1.094.410	2.971.213
65	Ogulin	1.844.914	870.807	2.697.232	2.001.881	768.490	1.234.112	1.683.352	1.619.621
66	Omiš	4.506.475	8.192.512	12.229.762	13.288.142	6.956.154	4.090.877	37.171.930	7.430.177
67	Opatija	18.234.997	13.524.860	21.707.648	20.960.932	18.816.073	19.790.510	24.106.665	19.182.215
68	Opuzen	1.534.601	2.163.649	999.216	1.051.888	1.032.917	1.214.774	1.924.728	1.437.204
69	Orahovica	1.043.036	952.498	1.939.338	935.629	958.076	887.932	760.179	866.091

70	Oroslavje	304.568	305.101	396.438	342.580	273.418	385.663	374.241	347.683
71	Osijek	38.528.169	26.587.376	31.684.606	23.325.222	21.600.449	24.222.119	21.865.620	47.133.247
72	Otočac	506.144	1.915.990	491.450	447.290	476.039	225.989	365.509	702.193
73	Otok	1.329.960	825.316	1.270.048	1.776.041	1.532.185	2.081.456	1.713.614	1.899.005
74	Ozalj	139.514	444.777	473.123	184.997	211.598	120.248	175.264	165.344
75	Pag	1.351.621	1.677.631	2.956.842	2.026.118	2.513.071	2.110.726	2.278.186	2.667.579
76	Pakrac	1.197.148	1.399.770	469.114	650.169	1.007.961	638.295	563.490	1.218.825
77	Pazin	9.574.704	10.920.595	6.242.091	4.457.302	4.745.286	3.977.800	5.263.147	5.179.992
78	Petrinja	696.278	661.314	558.592	544.513	426.438	324.739	428.582	1.488.732
79	Pleternica	587.969	411.097	680.194	889.822	495.628	874.082	548.271	650.125
80	Ploče	6.948.070	2.860.059	11.230.516	911.023	782.103	1.673.972	3.005.077	2.315.121
81	Poreč	61.591.708	26.322.933	9.264.230	8.997.090	10.036.800	13.322.739	22.307.727	26.609.672
82	Požega	1.344.654	2.020.415	1.654.382	1.466.701	3.771.557	2.287.543	3.848.379	3.230.083
83	Pregrada	90.928	401.349	631.349	619.790	420.937	459.806	416.466	357.855
84	Prelog	3.038.003	2.448.722	4.331.628	810.977	3.280.290	3.288.713	3.629.889	3.160.749
85	Pula	42.494.430	62.075.604	47.064.198	72.762.143	44.878.084	34.413.722	43.011.235	51.314.688
86	Rab	875.489	1.968.420	5.711.104	6.193.092	1.425.105	116.131	1.405.447	1.379.225
87	Rijeka	130.045.767	130.421.810	149.179.303	121.661.420	122.617.083	119.011.531	122.952.225	109.576.219
88	Rovinj	21.084.623	21.529.483	13.786.271	8.002.024	27.811.986	12.808.472	14.914.239	15.841.787
89	Samobor	6.109.877	8.052.745	2.746.834	3.970.463	3.237.520	6.710.233	3.633.430	10.645.739
90	Senj	4.778.112	2.773.548	2.462.061	1.771.144	1.801.162	2.811.280	1.547.167	1.466.213
91	Sinj	7.637.653	4.290.316	2.490.474	1.759.946	1.085.151	1.180.674	1.577.268	1.076.841
92	Sisak	12.055.836	9.275.418	7.491.283	4.367.518	5.003.621	4.366.890	5.958.287	5.292.212
93	Skradin	381.911	832.804	687.547	583.323	642.359	1.311.841	1.101.321	814.209
94	Slatina	5.098.369	3.067.597	2.914.605	6.886.467	1.541.960	1.953.459	2.821.568	1.344.065
95	Slavonski Brod	8.050.858	9.394.620	8.535.374	15.771.190	9.095.734	9.434.071	7.371.764	11.873.612
96	Slunj	848.487	542.808	1.805.092	1.503.264	1.298.111	1.323.504	1.781.001	649.146
97	Solin	4.688.788	4.366.627	4.034.704	4.478.307	4.532.607	10.539.018	7.617.008	3.489.008
98	Split	55.238.980	54.368.156	51.603.736	76.267.709	72.920.107	59.498.060	71.930.184	81.268.707

99	Stari Grad	229.805	418.073	207.354	187.180	161.703	802.226	1.193.906	239.852
100	Supetar	1.624.266	1.968.111	2.150.873	2.706.029	14.068.692	1.499.976	3.232.255	3.816.426
101	Sveta Nedelja	173.082	222.966	218.039	236.552	186.810	420.955	172.902	211.292
102	Sveti Ivan Zelina	353.670	312.461	318.159	286.229	229.598	266.244	250.808	221.469
103	Šibenik	8.078.510	9.908.366	7.468.971	7.320.358	6.891.817	9.235.918	9.601.197	8.647.487
104	Trilj	150.593	190.778	145.162	129.960	144.955	141.376	727.111	442.754
105	Trogir	5.434.993	8.258.143	10.108.148	8.972.947	7.675.930	8.729.910	9.518.250	10.276.228
106	Umag	11.785.587	10.481.474	11.748.792	31.564.208	17.486.923	15.960.956	22.372.610	14.615.431
107	Valpovo	2.961.886	1.353.601	1.785.954	1.076.834	1.355.084	1.227.298	1.571.215	1.242.379
108	Varaždin	32.446.355	24.322.802	21.873.567	27.143.883	30.364.559	25.900.825	28.212.120	24.419.156
109	Varaždinske Topl	141.985	197.806	142.692	82.982	74.108	100.771	297.952	92.589
110	Velika Gorica	19.855.201	5.652.005	4.211.191	15.320.017	4.414.901	4.740.588	7.243.679	5.682.640
111	Vinkovci	6.075.014	6.825.766	5.205.673	5.083.288	7.858.998	6.210.413	6.188.911	5.435.947
112	Virovitica	3.707.187	12.293.931	12.847.512	16.073.324	16.722.719	24.000.798	10.624.414	3.134.973
113	Vis	554.143	1.219.027	1.523.181	1.697.600	4.901.347	2.180.709	3.102.612	2.565.869
114	Vodice	236.761	922.115	493.027	551.899	419.868	428.314	405.831	389.970
115	Vodnjan	9.501.801	7.267.955	4.886.753	5.598.982	3.436.730	4.592.679	5.676.167	5.565.271
116	Vrbovec	793.933	1.612.730	930.376	709.955	791.011	822.272	1.660.041	751.624
117	Vrbovsko	489.599	468.286	484.634	731.079	535.340	474.584	446.112	449.291
118	Vrgorac	150.520	128.950	191.281	279.308	220.231	327.955	143.580	2.245.598
119	Vrlika	437.865	253.016	298.552	320.446	100.053	536.753	62.352	71.626
120	Vukovar	15.763.786	25.024.177	21.330.605	16.601.978	20.410.175	20.383.287	11.396.691	11.903.964
121	Zabok	441.201	1.024.999	240.818	233.089	811.448	253.908	590.798	280.214
122	Zadar	42.441.198	42.502.426	31.057.227	32.086.931	31.120.400	31.849.792	30.572.603	40.538.449
123	Zagreb	242.873.799	285.238.950	198.534.205	342.286.235	148.904.682	151.726.947	174.987.445	287.759.720
124	Zaprešić	5.109.981	17.617.071	4.483.332	4.634.121	4.450.179	5.011.822	4.912.944	6.240.357
125	Zlatar	21.952	19.006	9.977	71.994	10.157	11.964	9.166	7.933
126	Županja	6.897.949	966.665	2.278.359	1.314.071	1.917.512	1.301.568	2.701.993	1.381.311

Izvor: Ministarstvo financija

Prilog 8 Vrijednost nekretnina gradova

Rbr	Ime grada	2004	2005	2006	2007	2008	2009	2010
1	Bakar	25.903.728	47.268.610	53.707.534	58.151.889	62.120.742	87.969.069	90.130.760
2	Beli Manastir	2.943.127	4.010.254	4.068.254	4.160.454	27.252.381	32.052.511	31.855.202
3	Belišće	24.734.691	24.738.847	24.968.572	25.563.373	28.317.553	32.070.154	32.139.681
4	Benkovac	3.075.429	2.044.908	2.368.758	3.276.198	3.967.191	7.209.948	5.333.246
5	Biograd na Moru	16.625.298	17.670.676	17.586.338	17.586.338	20.351.575	20.803.478	29.644.946
6	Bjelovar	131.488.999	150.675.344	153.000.015	170.386.906	173.832.978	180.310.437	182.116.855
7	Buje	22.225.721	22.016.282	23.403.231	37.160.399	46.846.547	47.614.711	49.566.098
8	Buzet	7.681.088	8.693.526	11.919.277	12.381.656	16.164.037	17.932.316	18.203.055
9	Cres	9.117.242	9.568.470	28.134.248	31.619.178	32.037.118	34.023.374	40.697.963
10	Crikvenica	1.107.277.914	1.107.381.874	1.109.284.962	1.149.473.098	1.151.627.387	1.158.672.113	1.159.447.742
11	Čabar	55.283.584	56.472.398	56.661.546	45.292.576	56.688.815	56.688.815	56.763.240
12	Čakovec	88.441.282	97.141.773	97.211.251	97.254.743	99.315.308	106.675.387	115.538.827
13	Čazma	10.964.613	16.665.254	16.765.253	16.701.727	17.012.373	17.282.374	16.618.508
14	Daruvar	27.272.234	28.844.574	31.704.369	32.206.568	34.870.832	36.955.935	38.754.748
15	Delnice	26.366.256	26.512.270	28.395.949	235.665.954	251.535.926	122.380.444	123.186.282
16	Donja Stubica	5.863.978	5.863.978	29.481.619	30.814.950	29.179.308	29.229.204	29.288.466
17	Donji Miholjac	146.204.053	139.628.717	139.698.003	139.561.598	139.963.796	148.885.775	148.983.902
18	Drniš	6.073.794	22.017.592	10.498.034	11.332.760	13.964.439	14.807.178	15.826.185
19	Dubrovnik	1.268.767.328	1.220.727.912	1.211.772.608	1.201.815.516	1.195.866.858	1.194.418.741	1.204.149.482
20	Duga Resa	20.100.313	21.080.439	21.259.800	22.750.770	20.852.307	19.966.845	19.651.569
21	Dugo Selo	41.710.504	50.291.359	54.786.256	51.634.658	63.317.481	73.596.421	79.769.759
22	Đakovo	159.932.469	161.362.721	162.008.665	167.722.576	169.322.187	169.819.453	173.924.650
23	Đurđevac	56.529.986	56.110.300	61.599.713	61.018.925	61.253.106	60.641.030	61.016.113
24	Garešnica	38.334.958	37.750.796	38.219.490	38.459.037	59.748.300	62.814.768	68.113.637
25	Glina	33.564.869	35.057.684	49.159.622	49.222.655	52.303.117	51.291.426	58.386.957
26	Gospić	33.348.157	41.085.577	80.993.353	88.414.822	95.492.800	97.922.487	99.965.375

27	Grubišno Polje	14.941.538	14.764.842	15.760.879	16.847.745	21.454.563	23.567.476	23.214.103
28	Hrvatska Kostajnica	6.617.115	6.661.115	15.049.152	12.315.217	12.813.542	11.554.385	14.056.567
29	Hvar	19.480.785	20.101.838	20.831.826	24.348.194	33.343.256	34.931.725	27.719.988
30	Ilok	5.841.248	5.896.825	6.163.117	5.722.322	6.267.015	6.897.142	30.811.032
31	Imotski	7.650.950	7.452.127	11.447.655	11.984.652	17.655.130	20.049.845	27.344.034
32	Ivanec	16.223.674	15.508.496	15.402.160	18.428.117	18.933.498	19.266.100	19.701.995
33	Ivanić-Grad	38.566.900	39.379.498	50.840.209	57.530.896	59.047.067	59.682.392	59.754.783
34	Jastrebarsko	51.566.126	52.311.032	53.343.300	52.341.636	60.514.006	64.620.201	65.875.906
35	Karlovac	115.512.796	106.386.236	115.780.167	117.159.717	126.371.731	162.416.685	169.784.300
36	Kastav	30.242.269	31.958.057	34.413.043	37.033.328	40.160.535	41.135.246	45.448.033
37	Kaštela	25.706.251	34.698.842	48.766.413	53.319.231	64.962.619	66.821.818	67.784.079
38	Klanjec	1.487.659	1.503.493	1.625.493	2.225.680	2.229.900	2.229.901	2.306.039
39	Knin	5.530.110	6.500.742	6.711.860	70.113.444	71.093.120	29.146.910	41.224.517
40	Komiža	3.959.055	4.255.855	4.265.325	4.265.324	5.691.715	24.006.207	24.564.863
41	Koprivnica	103.836.113	103.617.441	104.567.448	114.780.791	169.006.728	173.233.759	180.135.799
42	Korčula	42.241.146	48.801.421	49.740.072	50.477.979	117.209.388	120.564.331	120.573.066
43	Kraljevica	22.314.538	21.576.070	21.611.754	28.864.182	183.277.291	183.298.690	183.368.420
44	Krapina	26.074.582	30.604.183	31.597.437	39.021.261	39.456.611	39.801.608	39.801.608
45	Križevci	207.791.658	207.766.722	213.356.040	290.267.920	272.164.444	273.537.576	272.057.405
46	Krk	35.806.757	55.268.664	38.022.372	41.175.239	43.325.593	69.653.215	74.414.331
47	Kutina	146.402.087	164.589.455	166.553.634	156.753.701	157.781.152	156.856.577	174.946.732
48	Labin	45.459.164	46.658.470	53.207.156	54.916.179	55.129.995	94.653.688	96.330.884
49	Lepoglava	3.335.346	4.881.687	7.118.130	8.536.010	14.485.113	18.968.665	21.782.128
50	Lipik	18.816.664	20.820.195	22.765.626	23.250.085	23.615.649	29.443.166	29.133.968
51	Ludbreg	95.377.579	97.504.078	113.527.764	109.685.856	113.750.035	113.705.027	118.565.709
52	Makarska	64.717.497	72.057.223	73.655.546	74.943.307	75.254.362	163.194.062	164.452.379
53	Mali Lošinj	99.362.041	108.198.043	111.826.599	105.689.636	111.951.372	126.575.584	202.139.063
54	Metković	19.764.942	26.840.386	34.386.558	39.631.066	41.789.500	44.088.536	46.159.512

55	Mursko Središće	14.207.865	14.616.469	15.303.839	15.497.086	18.002.686	20.585.434	21.449.454
56	Našice	16.570.042	17.055.879	20.055.401	23.942.794	25.199.587	26.921.872	34.736.757
57	Nin	230.581.490	230.120.859	230.807.648	165.389.943	164.850.652	164.636.186	164.349.032
58	Nova Gradiška	173.781.165	176.233.844	173.122.828	171.775.123	172.407.435	243.171.268	244.078.441
59	Novalja	10.152.146	11.735.690	13.092.102	14.436.465	17.264.217	19.688.694	22.429.197
60	Novi Marof	9.223.360	9.573.038	11.130.002	11.791.470	15.711.831	16.451.019	17.698.945
61	Novi Vinodolski	11.975.970	10.025.061	19.499.832	21.577.909	108.315.051	108.315.051	118.273.177
62	Novigrad-Cittanova	3.909.132	7.099.434	12.562.907	206.363.404	215.251.135	216.908.541	217.753.577
63	Novska	54.783.323	49.491.207	50.573.070	54.956.878	58.540.224	59.379.865	76.746.759
64	Obrovac	5.575.778	5.602.153	5.602.153	17.061.302	8.445.816	8.383.862	6.263.061
65	Ogulin	478.730.170	480.824.708	483.476.842	495.874.920	511.720.614	528.668.585	529.707.390
66	Omiš	26.705.407	27.020.475	28.448.192	28.661.893	28.058.470	28.900.415	29.029.302
67	Opatija	93.223.596	98.525.643	100.861.044	107.459.659	112.951.836	117.426.213	176.493.512
68	Opuzen	11.186.081	11.668.394	12.163.145	12.781.766	18.860.419	18.905.803	9.736.866
69	Orahovica	27.922.775	29.746.219	30.048.719	29.629.379	29.764.587	31.288.614	31.455.368
70	Oroslavje	6.305.359	6.305.359	6.793.907	9.066.076	9.093.420	9.303.196	9.387.287
71	Osijek	332.842.677	360.681.634	374.561.073	399.278.604	400.013.136	559.255.351	1.038.373.671
72	Otočac	6.527.711	6.495.364	6.748.456	9.380.930	21.685.329	27.595.202	29.842.512
73	Otok	1.832.777	1.832.777	1.931.663	3.526.729	7.957.377	8.499.372	8.024.087
74	Ozalj	11.642.484	12.167.001	12.157.863	12.968.029	16.306.575	16.771.061	17.641.800
75	Pag	20.182.131	20.426.337	20.553.045	20.865.730	21.488.087	21.774.295	21.953.654
76	Pakrac	75.737.044	79.101.486	81.392.930	83.211.240	85.391.097	86.570.508	93.543.292
77	Pazin	24.969.864	23.620.202	23.010.882	37.150.230	37.150.232	37.150.232	37.180.232
78	Petrinja	206.413.076	215.817.149	222.116.753	232.948.145	253.963.378	251.234.126	246.087.393
79	Pleternica	9.043.493	9.438.383	6.550.625	7.036.238	8.690.736	15.106.139	15.135.974
80	Ploče	5.913.094	6.286.306	6.329.519	17.685.099	18.508.175	18.709.522	18.709.522
81	Poreč	131.394.609	130.147.569	134.239.076	348.275.500	396.645.254	463.254.576	468.844.702
82	Požega	80.353.495	107.344.232	111.098.437	118.059.792	134.192.413	140.144.225	174.258.336
83	Pregrada	12.991.473	13.414.203	17.409.675	19.456.418	21.923.021	21.827.613	25.787.168

84	Prelog	32.839.661	35.115.946	36.818.795	38.321.798	30.366.886	35.667.000	41.057.726
85	Pula	256.449.878	368.323.129	405.454.242	435.731.140	2.867.279.181	2.831.926.433	2.855.508.630
86	Rab	37.216.416	37.822.674	39.252.946	51.258.190	56.848.803	60.037.375	57.944.842
87	Rijeka	2.657.226.192	2.664.945.279	2.887.102.261	2.849.396.988	2.926.878.860	4.295.353.716	5.070.467.209
88	Rovinj	783.105.833	782.466.404	772.293.463	757.610.961	761.390.152	773.750.273	777.138.909
89	Samobor	55.631.070	59.822.757	70.148.013	77.100.929	87.337.548	97.340.434	135.767.782
90	Senj	13.005.888	13.010.756	12.438.811	19.145.512	24.444.980	24.474.950	25.362.807
91	Sinj	12.375.732	12.436.627	13.180.092	13.180.092	25.402.605	26.419.315	27.020.356
92	Sisak	133.959.402	138.532.339	146.688.875	186.798.122	204.813.343	212.828.880	216.851.249
93	Skradin	2.145.900	2.165.483	2.230.536	2.663.619	3.324.270	3.687.663	4.521.351
94	Slatina	24.313.748	25.968.612	34.331.870	39.061.369	54.494.490	57.378.670	57.675.790
95	Slavonski Brod	130.229.810	135.945.485	166.624.105	165.852.674	166.090.905	350.963.729	393.877.695
96	Slunj	32.577.289	18.644.213	8.641.210	11.389.340	18.981.445	18.559.227	18.508.461
97	Solin	78.844.620	81.517.386	88.584.051	95.038.683	146.541.370	168.902.401	172.023.944
98	Split	539.410.689	582.797.310	617.979.283	791.498.188	1.994.621.927	3.156.104.199	3.435.537.457
99	Stari Grad	6.909.784	8.432.183	16.460.204	17.881.439	34.629.805	35.309.145	35.773.969
100	Supetar	539.741	2.289.901	9.970.961	10.146.881	10.566.548	17.076.844	63.735.814
101	Sveta Nedelja	15.011.583	22.338.357	26.474.803	30.362.393	37.162.921	39.871.382	40.737.700
102	Sveti Ivan Zelina	28.710.669	30.005.941	32.446.413	34.337.714	37.342.226	38.037.621	39.012.000
103	Šibenik	333.736.862	508.244.303	349.347.753	357.016.723	365.169.097	369.383.978	378.096.751
104	Trilj	3.148.850	3.374.839	0	4.724.893	6.727.737	10.682.394	12.267.200
105	Trogir	44.372.535	44.265.219	44.071.623	46.726.186	47.788.433	46.376.398	46.370.534
106	Umag	99.442.784	105.778.147	108.814.353	173.645.800	182.747.839	193.354.410	204.508.894
107	Valpovo	49.857.193	49.316.697	49.162.982	49.269.615	50.659.305	52.507.479	51.552.563
108	Varaždin	224.224.943	228.497.025	232.318.812	250.521.364	322.008.007	423.430.981	489.268.317
109	Varaždinske Topl	4.660.000	5.586.805	5.767.945	5.740.165	9.650.442	13.175.176	17.292.433
110	Velika Gorica	12.957.066	14.788.344	14.959.663	17.819.154	33.175.203	36.017.023	46.079.880
111	Vinkovci	94.888.093	99.056.722	101.725.653	97.528.602	100.836.818	104.357.731	188.142.786
112	Virovitica	58.135.575	63.807.085	66.238.600	77.680.701	87.138.204	102.360.279	115.735.312

113	Vis	4.222.173	4.279.574	4.341.562	4.341.562	13.341.562	13.933.666	14.004.619
114	Vodice	5.632.774	17.049.895	43.442.339	50.611.514	55.723.982	59.189.891	60.682.478
115	Vodnjan	10.866.237	11.633.118	40.354.945	44.068.634	54.602.692	57.751.880	60.714.726
116	Vrbovec	27.776.315	29.049.770	29.420.159	28.116.956	16.275.059	16.275.059	16.475.059
117	Vrbovsko	14.063.896	14.063.896	15.452.971	18.336.645	35.234.436	38.824.859	38.831.159
118	Vrgorac	6.717.255	10.436.551	10.542.030	13.427.013	13.741.803	14.931.680	16.525.729
119	Vrlika	10.828.371	11.743.371	11.767.451	12.027.452	12.336.763	12.339.735	12.423.823
120	Vukovar	281.723.068	281.723.068	281.774.028	299.712.163	309.166.806	266.619.267	266.333.919
121	Zabok	10.635.991	11.803.858	17.350.654	20.579.985	20.211.795	19.815.302	29.264.323
122	Zadar	180.654.390	198.910.918	239.731.293	298.061.283	314.545.201	333.567.905	420.090.390
123	Zagreb	3.170.099.065	3.319.417.542	3.343.552.354	3.518.168.092	3.843.803.606	3.873.703.387	3.972.457.036
124	Zaprešić	61.788.257	69.046.937	73.079.080	89.508.432	98.436.367	103.513.130	107.208.463
125	Zlatar	8.302.234	8.385.927	8.414.024	8.289.756	8.315.256	8.315.256	8.315.256
126	Županja	34.831.022	110.172.401	112.166.210	111.903.807	117.357.274	86.120.844	83.007.614
Rbr	Ime grada	2011	2012	2013	2014	2015	2016	2017
1	Bakar	220.470.663	409.716.865	413.743.167	416.912.079	424.249.609	428.996.070	432.653.822
2	Beli Manastir	55.703.924	56.607.189	60.201.582	64.628.738	66.581.224	72.424.515	73.388.690
3	Belišće	44.639.950	44.219.551	43.731.736	76.443.351	75.642.404	78.044.251	79.227.262
4	Benkovac	5.333.246	5.964.456	6.412.657	8.343.914	8.501.796	8.607.331	9.934.944
5	Biograd na Moru	54.063.221	57.826.834	61.854.895	67.428.217	70.361.854	73.629.527	79.204.554
6	Bjelovar	192.667.126	203.169.951	210.420.934	214.089.778	214.747.741	217.291.227	222.074.621
7	Buje	72.075.263	73.238.617	75.318.049	76.331.989	78.157.498	78.185.781	80.848.705
8	Buzet	18.937.760	19.129.803	21.547.085	28.802.323	200.545.416	201.435.722	201.274.197
9	Cres	60.547.281	60.854.986	61.073.286	61.389.245	62.096.509	64.200.878	69.608.327
10	Crikvenica	1.173.591.841	1.309.034.100	281.104.023	281.848.294	283.893.432	286.140.434	299.377.025
11	Čabar	57.085.366	58.456.337	58.562.665	62.056.809	62.068.689	62.068.689	62.075.689
12	Čakovec	132.643.636	147.935.587	151.267.745	157.243.326	159.167.580	170.579.936	173.864.020
13	Čazma	16.774.508	16.798.747	16.870.225	17.020.225	18.944.303	20.232.243	31.455.886
14	Daruvar	51.937.273	51.723.454	89.152.258	89.294.218	94.876.757	95.426.473	95.474.963

15	Delnice	125.538.254	125.844.090	127.274.055	134.320.079	137.325.516	191.131.574	191.145.770
16	Donja Stubica	28.663.825	28.338.087	28.571.040	28.526.816	28.163.608	43.414.856	43.622.512
17	Donji Miholjac	149.401.468	147.567.844	146.642.724	146.410.820	146.503.343	146.842.890	146.090.354
18	Drniš	16.133.884	16.182.285	16.524.101	16.859.040	17.108.360	12.364.394	12.466.812
19	Dubrovnik	5.245.070.382	5.140.402.558	5.110.738.235	5.165.248.522	5.334.306.977	5.339.768.407	5.340.543.627
20	Duga Resa	20.003.772	21.942.587	21.104.860	15.416.340	16.146.912	19.551.631	19.932.433
21	Dugo Selo	98.720.273	95.249.747	87.635.571	88.466.289	98.065.703	114.087.429	113.969.336
22	Đakovo	174.722.710	178.030.741	180.603.455	180.740.454	198.054.622	209.554.672	214.093.748
23	Đurđevac	66.043.776	66.043.776	63.862.382	68.286.542	72.453.747	68.795.915	69.542.801
24	Garešnica	68.047.548	69.997.802	70.624.340	71.757.582	72.383.074	73.325.857	74.462.765
25	Glina	59.665.206	64.750.989	66.056.987	65.522.775	66.914.274	67.572.848	68.874.188
26	Gospić	102.043.207	107.450.843	107.524.307	111.692.623	184.331.926	183.427.293	183.738.132
27	Grubišno Polje	41.761.122	42.220.483	44.816.453	44.712.472	45.266.509	48.072.844	48.741.561
28	Hrvatska Kostajnica	13.973.091	13.973.091	15.180.927	14.670.332	13.105.775	12.701.775	12.746.775
29	Hvar	22.809.322	22.902.467	24.060.557	25.872.848	25.292.747	27.605.147	29.938.314
30	Ilok	31.525.595	33.415.903	33.266.907	41.775.652	34.085.288	34.085.288	38.516.174
31	Imotski	31.841.130	34.495.227	34.890.063	34.890.063	34.902.064	35.204.727	35.210.780
32	Ivanec	19.971.478	19.802.051	19.848.161	64.176.211	68.212.096	70.592.392	72.652.155
33	Ivanić-Grad	61.000.144	61.682.533	76.933.088	77.335.473	77.812.467	78.028.788	78.626.429
34	Jastrebarsko	76.035.020	77.334.220	86.515.996	99.894.620	87.811.966	91.014.642	91.377.073
35	Karlovac	161.384.380	229.733.575	428.349.007	457.162.889	271.644.535	400.406.266	365.652.538
36	Kastav	86.327.176	298.765.255	297.726.274	298.615.633	300.227.955	317.342.976	321.912.189
37	Kaštela	75.905.534	79.756.904	94.818.155	95.581.854	96.786.445	120.041.639	121.271.105
38	Klanjec	2.518.915	2.421.330	2.905.551	3.215.444	3.971.169	4.231.169	4.231.169
39	Knin	44.498.789	43.798.232	43.005.189	43.234.858	43.856.861	50.581.807	51.014.507
40	Komiža	24.999.193	26.863.335	36.420.380	37.273.532	38.576.239	39.065.297	39.165.997
41	Koprivnica	243.561.210	279.104.296	297.088.218	327.114.085	325.083.110	325.789.590	352.183.113
42	Korčula	120.852.234	121.041.070	122.336.668	133.758.735	134.897.948	136.794.656	137.793.443

43	Kraljevica	183.286.076	183.235.371	183.182.812	183.842.210	200.392.164	205.020.865	205.466.432
44	Krapina	40.977.308	41.039.408	41.103.900	40.524.154	39.266.830	39.602.199	42.047.551
45	Križevci	277.109.516	172.913.008	184.133.361	176.930.079	190.153.009	209.517.062	234.435.598
46	Krk	76.161.701	79.364.238	93.952.126	122.848.162	125.194.890	127.009.645	128.292.280
47	Kutina	172.570.421	172.079.400	181.608.053	181.383.221	181.383.221	311.859.849	311.941.548
48	Labin	97.473.037	93.815.226	134.118.393	172.590.608	207.101.365	216.237.654	275.019.265
49	Lepoglava	21.296.336	21.292.813	21.719.331	21.955.110	22.571.079	22.622.060	23.047.667
50	Lipik	32.860.201	32.027.835	32.769.778	32.514.833	32.093.945	32.676.401	32.638.709
51	Ludbreg	108.048.739	73.881.168	84.402.424	231.378.662	233.561.011	263.124.822	261.697.772
52	Makarska	165.257.565	167.291.934	168.878.282	170.043.725	171.084.367	175.005.645	183.377.113
53	Mali Lošinj	201.030.966	563.786.721	576.399.439	587.909.606	1.204.335.123	1.209.937.542	1.211.631.683
54	Metković	15.466.383	35.918.558	18.773.171	19.273.257	25.158.195	25.229.989	25.232.317
55	Mursko Središće	23.738.158	24.187.280	25.038.754	26.022.351	29.021.530	35.088.811	41.652.771
56	Našice	38.863.895	39.947.939	36.635.981	57.588.286	72.017.571	75.012.747	76.417.011
57	Nin	164.202.215	165.115.193	166.127.825	167.156.821	167.724.390	171.781.496	172.484.113
58	Nova Gradiška	241.034.283	242.397.706	236.896.565	234.848.910	241.815.075	247.659.841	247.685.325
59	Novalja	24.828.825	26.384.706	25.873.185	29.333.282	31.517.550	37.404.200	42.389.393
60	Novi Marof	43.148.317	47.084.574	47.296.739	46.606.228	46.779.907	46.974.068	49.976.345
61	Novi Vinodolski	237.066.587	236.742.603	467.117.992	474.032.999	451.222.460	451.190.069	470.579.057
62	Novigrad-Cittanova	226.656.032	217.819.075	223.114.014	228.420.139	221.609.675	214.940.985	214.501.204
63	Novska	96.713.708	95.968.579	98.624.928	100.022.045	100.472.224	100.534.214	109.076.520
64	Obrovac	6.726.247	7.253.996	7.687.219	10.129.455	12.682.545	13.853.440	14.337.094
65	Ogulin	532.866.650	531.071.647	531.438.925	321.863.615	321.131.534	322.154.496	357.717.982
66	Omiš	29.037.604	29.037.604	27.872.664	31.346.853	32.679.831	37.629.945	37.629.945
67	Opatija	213.840.481	225.651.929	238.784.164	277.625.271	286.250.620	295.529.102	348.157.135
68	Opuzen	52.695.659	52.805.280	52.821.276	53.773.829	53.773.829	53.870.829	53.969.231
69	Orahovica	35.326.280	35.463.441	27.411.097	27.818.794	27.299.993	28.940.575	32.852.058
70	Oroslavje	9.654.168	9.758.202	10.306.240	13.475.722	13.946.231	15.509.632	16.623.603
71	Osijek	1.075.252.524	1.107.452.834	1.359.600.921	1.465.194.146	1.500.615.658	1.533.398.037	1.560.786.582

72	Otočac	34.735.660	45.769.796	45.781.659	45.720.696	46.686.103	49.513.781	59.288.473
73	Otok	8.048.945	8.375.970	8.668.080	8.688.076	18.415.257	19.450.868	20.321.196
74	Ozalj	19.121.754	19.154.919	20.704.754	21.169.549	21.618.426	21.928.414	22.686.170
75	Pag	22.001.303	22.497.682	22.591.105	22.523.093	22.698.847	23.066.064	24.088.561
76	Pakrac	93.981.571	95.020.663	104.442.032	104.142.585	104.645.534	105.106.193	105.760.564
77	Pazin	100.820.364	99.141.392	92.498.747	92.498.747	92.508.450	126.631.361	126.816.936
78	Petrinja	249.628.183	253.403.897	257.134.765	211.987.361	186.195.987	189.898.271	175.106.581
79	Pleternica	16.668.382	15.613.627	21.079.119	31.867.015	43.769.275	47.885.032	48.484.147
80	Ploče	25.181.837	27.586.290	27.091.966	27.481.410	27.567.577	27.987.316	29.563.306
81	Poreč	467.687.435	410.144.807	411.454.670	413.427.910	422.598.264	427.712.588	442.577.106
82	Požega	188.219.330	196.956.300	212.045.604	224.353.330	227.875.753	355.168.921	371.960.323
83	Pregrada	26.460.518	28.208.355	38.486.573	44.493.257	47.145.170	48.433.962	48.956.545
84	Prelog	50.193.861	52.463.906	57.115.445	58.062.790	64.706.593	65.293.129	66.063.789
85	Pula	3.086.845.410	3.319.694.320	3.318.773.334	3.063.407.099	12.831.025.238	8.813.607.853	8.301.497.161
86	Rab	58.799.498	68.322.110	61.390.665	64.953.561	65.957.265	67.527.839	69.982.676
87	Rijeka	5.547.502.408	5.826.499.717	6.071.042.314	6.601.958.331	6.687.123.042	6.860.963.041	6.965.318.157
88	Rovinj	726.569.454	790.455.059	789.651.794	757.044.595	755.077.167	748.764.443	699.635.872
89	Samobor	193.864.599	195.021.258	201.681.479	202.971.441	255.248.438	259.466.610	269.963.425
90	Senj	41.796.791	41.128.788	40.760.676	40.913.308	41.818.276	49.745.792	50.721.560
91	Sinj	26.909.666	25.099.772	197.683.591	227.207.781	226.904.467	226.664.765	226.603.235
92	Sisak	227.633.146	310.466.861	310.875.858	366.353.228	367.790.130	379.493.632	420.274.096
93	Skradin	4.539.800	4.539.800	4.539.800	8.915.955	8.419.248	8.437.858	8.883.237
94	Slatina	63.852.976	66.715.689	61.967.564	61.175.156	62.736.101	64.483.277	65.510.366
95	Slavonski Brod	401.233.387	413.026.672	482.864.941	513.328.473	1.129.760.898	1.164.458.184	1.185.816.681
96	Slunj	19.306.882	18.924.228	33.230.343	47.832.665	41.497.066	43.722.584	44.444.417
97	Solin	173.835.581	178.420.224	179.203.078	171.026.043	182.858.007	185.421.349	187.205.639
98	Split	2.837.027.110	2.876.453.959	2.886.965.246	2.965.017.540	3.177.659.384	3.511.741.556	4.000.529.161
99	Stari Grad	36.181.682	36.511.154	36.574.041	44.554.255	50.808.318	50.907.965	46.000.872
100	Supetar	35.207.551	34.574.728	34.609.581	34.962.351	35.624.511	35.984.869	29.198.256

101	Sveta Nedelja	46.752.818	48.121.673	48.915.512	50.419.158	71.036.252	71.640.330	76.540.286
102	Sveti Ivan Zelina	39.138.384	41.407.540	42.330.844	43.363.863	44.316.532	45.037.870	45.349.454
103	Šibenik	372.541.744	408.087.536	409.794.645	426.859.020	448.829.874	456.824.278	460.207.424
104	Trilj	12.267.203	12.267.203	12.361.125	13.311.412	13.311.412	13.311.412	17.504.621
105	Trogir	46.114.931	47.287.190	47.287.190	47.287.190	47.318.679	48.739.096	51.417.480
106	Umag	207.288.452	149.820.670	175.218.075	225.018.209	231.478.246	1.627.008.438	1.663.776.676
107	Valpovo	55.251.189	63.243.692	63.287.179	72.277.976	72.380.593	72.577.819	73.390.954
108	Varaždin	492.732.519	470.520.575	490.435.849	505.367.132	507.893.832	516.329.070	642.084.997
109	Varaždinske Topl	17.576.843	17.841.501	17.648.950	17.648.950	18.586.515	19.491.515	24.508.342
110	Velika Gorica	66.737.419	95.865.089	124.366.778	127.336.475	202.778.366	212.552.062	232.284.168
111	Vinkovci	185.545.510	186.073.328	707.270.342	707.980.412	706.728.535	698.296.015	699.694.556
112	Virovitica	182.932.439	186.998.411	186.183.355	203.707.021	219.929.443	220.961.394	219.583.939
113	Vis	20.929.519	21.033.078	31.033.454	36.921.619	37.187.125	38.878.046	443.197.266
114	Vodice	67.535.510	72.588.606	73.873.809	77.014.973	87.641.830	89.051.932	90.064.247
115	Vodnjan	61.875.143	63.453.638	66.388.903	70.120.940	74.084.091	76.655.193	78.839.723
116	Vrbovec	20.222.058	29.198.835	31.342.749	35.774.171	68.774.901	68.844.052	69.490.594
117	Vrbovsko	39.513.562	39.787.590	40.140.568	40.351.721	26.386.571	26.848.723	26.951.265
118	Vrgorac	17.434.013	18.169.234	19.880.833	23.980.228	25.995.133	27.310.555	30.554.281
119	Vrlika	12.309.407	12.282.174	12.282.174	12.209.973	12.447.809	12.309.989	12.404.489
120	Vukovar	277.658.878	280.971.972	304.904.684	305.621.506	310.736.694	292.545.625	406.411.862
121	Zabok	29.035.221	29.035.221	31.246.825	31.100.837	32.063.981	31.744.810	39.473.607
122	Zadar	418.490.715	447.778.400	603.474.238	653.567.684	656.638.227	716.130.007	736.268.630
123	Zagreb	4.134.551.082	4.064.227.616	4.192.814.063	5.310.635.494	5.409.718.887	5.808.978.736	6.050.852.541
124	Zaprešić	152.071.210	212.742.922	219.955.526	222.497.090	224.537.488	234.184.724	236.417.144
125	Zlatar	8.335.256	8.366.873	8.771.933	8.934.052	9.187.944	12.284.568	16.600.752
126	Županja	82.987.357	84.852.918	81.182.939	81.583.492	73.226.532	73.226.532	74.672.945

Izvor: Ministarstvo financija

Prilog 9 Tablica varijabli korištenih u analizi

Naziv varijable	Definicija varijable	Način mjerenja
Vrijednost nekretnina	Vrijednost nekretnina predstavlja vrijednost imovine iskazanoj u bilanci na dan 31.12., koja spada u skupinu 01 nefinancijska imovina, i pod skupinu 011 Materijalna imovina – prirodna bogatstva, odjeljak 0111 zemljište, te skupinu 02, pod skupinu 21, odjeljak 0211 stambeni objekti i odjeljak 0212 poslovni objekti	Sekundarni podaci Varijabla se izražava kao broj koji predstavlja ukupno vrijednost nekretnina Izvor: Državna revizija; Ministarstvo financija
Prihod od nekretnina	Prihod od nekretnina predstavlja ukupan iznos prihoda iskazanih u izvještaju PR-RAS, funkcijski, razina 22, koje čine: a) prihodi imovine (razred 64), prihodi od nefinancijske imovine (pod skupina 642), Prihod za zakupa i iznajmljivanja imovine (odjeljak 6422); b) Prihodi od prodaje neproizvedene dugotrajne imovine (razred 71), prirodna bogatstva (pod skupina 711), Zemljišta (odjeljak 7111); c) Prihodi od prodaje proizvedene dugotrajne imovine (razred 72), prihod od prodaje građevinskih objekata (pod skupina 721), stambeni objekti (odjeljak 7211); Prihodi od prodaje proizvedene dugotrajne imovine (razred 72), prihod od prodaje građevinskih objekata (pod skupina 721), poslovni objekti (odjeljak 7212)	Sekundarni podaci Varijabla se izražava kao broj koji mjeri prihod od nekretnina Izvor: Ministarstvo financija
Pokazatelj učinkovitosti upravljanja nekretninama	Metodom omeđivanja podataka (DEA) izračunati će se pokazatelj učinkovitosti upravljanja nekretninama u gradovima, koji će u radu biti označen kao θ. DEA analiza će se u ovom radu temeljiti na jednom inputu i jednom outputu. Kao input će se	Sekundarni podaci Varijabla se izražava kao broj koji predstavlja pokazatelj učinkovitosti a radi se o relativnoj efikasnosti čija se vrijednost nalazi između 0 i 1. Izvor: Ministarstvo financija

	koristiti vrijednost nekretnina, a kao output prihodi od nekretnina	
Veličina grada	Veliki je grad je jedinica lokalne samouprave koja je ujedno gospodarsko, financijsko, kulturno, zdravstveno, prometno i znanstveno središte razvitka šireg okruženja i koja ima više od 35.000 stanovnika. Srednji grad je onaj s brojem stanovnika između 10.000 i 35.000, te mali grad s brojem stanovnika manjim od 10.000	Sekundarni podaci Varijabla je definirana kao odabir jedne od tri moguće veličine grada Izvor: Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, NN 33/01, 60/01, 129/05, 109/07, 125/08, 36/09, 36/09, 150/11, 144/12, 19/13, 137/15, 123/17
Gradovi sjedišta županija	Zakon o područjima županija, gradova i općina u Republici Hrvatskoj definira koji gradovi su sjedišta Županija	Sekundarni podaci Varijabla je definirana kao binarna varijabla, koja će poprimiti vrijednost 1 za gradove sjedišta županija i 0 za ostale gradove Izvor: Zakon o područjima županija, gradova i općina u Republici Hrvatskoj, NN: 86/06, 125/06, 16/07, 95/08, 46/10, 145/10, 37/13, 44/13, 45/13, 110/15
Lokacija gradova	Lokacije gradova na obali mora predstavljaju one gradovi koji svojim rubnim granicama područja se nalaze i/ili dodiruju morsku obalu	Sekundarni podaci Varijabla je definirana kao binarna varijabla, koja će poprimiti vrijednost 1 za gradove uz more i 0 za ostale gradove Izvor: Državna geodetska uprava
Broj stanovnika	Broj stanovnika prema DZS. Procjena stanovništva po gradovima na 31.12.	Sekundarni podaci Ukupan broj stanovnika u pojedinom gradu Izvor: Državni zavod za statistiku
Transparentnost gradova	Proračunska transparentnost gradova podrazumijeva uvid u potpune, točne, pravovremene i razumljive informacije o proračunu.	Sekundarni podaci Varijabla će biti preuzeta iz publikacije i baze podataka *Transparentnost proračuna lokalnih jedinica* Izvor: Institut za javne financije
Fiskalni kapacitet	Fiskalni kapacitet predstavlja sposobnost gradova da vlastitim proračunskim sredstvima financiraju proračunske rashode.	Sekundarni podaci Varijabla se mjeri kao odnos ukupnog prihoda poslovanja i broja stanovnika u pojedinom gradu Izvor: Ministarstvo financija, Državni zavod za statistiku
Broj poduzetnika	Broj poduzetnika predstavlja broj aktivnih gospodarskih subjekata	Sekundarni podaci

	koji su u Registar godišnjih financijskih izvještaja dostavili, u roku potpuni i točan godišnji financijski izvještaj na području gradova	Varijabla će se mjeriti aktivnim brojem poduzetnika prema podacima iz registra Fine normaliziranim brojem stanovnika na temelju podataka Državnog zavoda za statistiku, pri čemu je Grad Zagreb=100 Izvor: Financijska agencija, Državni zavod za statistiku
Nezaposlenost stanovništva	Nezaposlenost stanovništva prikazuje koliko je udio stanovništva u pojedinom gradu u promatranoj godini bio nezaposlen	Sekundarni podaci u postotku Varijabla se definira kao omjer ukupnog broja nezaposlenih i ukupnog broja stanovnika u pojedinom gradu Izvor: Hrvatski zavod za zapošljavanje
PRLS Model	PRLS model upravljanja nekretninama predstavlja paket koje obuhvaća 11 aktivnosti s ciljem postizanja kvalitetnije i učinkovitijeg upravljanju nekretninama u vlasništvu gradova	Sekundarni podaci Varijabla se definira kao binarna varijabla koja poprima vrijednost 1 u gradovima koji primjenjuju PRLS model i 0 u onima koji ga ne primjenjuju Izvor: Udruga gradova u Republici Hrvatskoj, LIBUSOFT CICOM d.o.o.

Izvor: Obrada autora

POJMOVNIK

Administrativna decentralizacija – sastoji se od skupa politika koje prenose administraciju i pružanje javnih usluga na niže razine vlasti.

AOMP (DEA) – analiza omeđivanja podataka (*data envelopment analysis*).

Decentrabilnost javnih funkcija – podobnost decentralizacije javnih funkcija.

Decentralizacija – prijenos pravnog i političkog autoriteta za planiranje, donošenje odluka i upravljanje javnim funkcijama sa središnje države na regionalne i lokalne razine vlasti.

Decentralizacija javne uprave – označava prenošenje poslova javne uprave sa središnje države na lokalne jedinice. Može se kvantificirati izračunom udjela rashoda za zaposlene u lokalnim jedinicama u ukupnim rashodima za zaposlene na razini opće države.

Direktne i indirektne subvencije – direktne subvencije su donacije gotovine primatelju, za razliku od indirektnih subvencija koje se daju (i prepoznaju) u obliku smanjenog najma ili pak bez najma/zakupa za upotrebu prostora na lokaciji bolje kvalitete od one kakva je primatelju potrebna, ili druge negotovinske koristi.

Financijski kapacitet – označava maksimalne prihode koje lokalna jedinica može prikupiti u

Fiskalna autonomija – označava stanje u kojem lokalne jedinice imaju dovoljno vlastitih resursa za financiranje znatnog dijela troškova koje snose u izvršavanju svojih odgovornosti. Fiskalna autonomija podrazumijeva i diskreciju lokalnih jedinica u poreznoj politici, posebno u određivanju poreznih stopa.

Fiskalna decentralizacija – prenošenje odgovornosti pružanja javnih usluga i izvora financiranja sa središnje države na niže razine vlasti (lokalne jedinice).

Fiskalne potrebe – teorijski iznos koji je lokalnim jedinicama potreban za proizvodnju ili pružanje unaprijed određenog skupa dobara i usluga na standardnoj razini.

Fiskalni kapacitet – označava maksimalne prihode koje lokalna jedinica može prikupiti u standardnim uvjetima koji su zadani na nacionalnoj razini.

Fiskalno izravnanje – mehanizam ublažavanja vodoravnih fiskalnih nejednakosti. U literaturi se spominje i izraz fiskalno poravnanje.

Jedinica imovina – najmanja funkcionalna cjelina neke nekretnine (npr. stan, garaža, poslovni prostor, soba u samačkom hotelu, groblje, parkiralište, javna rasvjeta (jedne ulice – mjernog mjesta), katastarska čestica, nerazvrstana cesta, most, i dr.).

Jedinice lokalne samouprave / lokalne jedinice (JLS) – administrativne jedinice najnižih razina vlasti (u Hrvatskoj su to gradovi i općine). Ponekad se pod lokalnim jedinicama mogu

podrazumijevati i sve administrativne jedinice nižih razina vlasti hijerarhijski podređenih središnjoj državi.

JLP(R)S – jedinica lokalne i područne (regionalne) samouprave, županija, grad i općina.

Kapitalna ulaganja – dodaci jedinici nekretnine koji dodaju vrijednost kroz proširenje njezina gospodarskog života, povećanje potencijalnog prihoda od najma, smanjenje operativnih troškova ili poboljšanje udobnosti za korisnike. Primjeri uključuju izmjenu krova, instalaciju komponenti koje čuvaju energiju kao što je izolacija ili poboljšana oprema za grijanje, te proširenje prostora grada. Ne uključuju gorivo, popravak krova, ličenje i druge rutinske operacije održavanja popravka.

Klasifikacija imovine – podjela imovine prema različitim funkcijama lokalne samouprave:A – obvezna – odgovornost lokalne samoupravne određena je zakonom.B – diskrecijska – dobrovoljno podržana iz društvenih, političkih, socijalnih, kulturnih ili drugih razloga.C – imovina za ostvarivanje prihoda za koju trebaju vrijediti sva tržišna pravila.

Lokalna država – sektor države koji se odnosi na administrativne jedinice najniže razine vlasti – lokalne jedinice. Ponekad se pod izrazom lokalna država može podrazumijevati i sektor države koji obuhvaća sve niže razine vlasti.

NN – Narodne novine, službeni list (glasilo) Republike Hrvatske.

Operativni izvještaj – računovodstveni izvještaj koji prikazuje sve prihode i izdatke povezane s funkcioniranjem jedinice nekretnine i podijeljen je u kategorije transakcija kao što su prihod od najma/zakupa, održavanje, struja i dr. Treba uključivati kategorije potrebne za točno prikazivanje financijskih rezultata imovine. On prikazuje neto operativni prihod.

Porezni potencijal lokalnih jedinica – označava mogućnost oporezivanja, tj. mogućnost prikupljanja poreznih prihoda.

Portfelj – skupina istovrsnih jedinica imovine, odnosno istovrsnih pojavnih oblika imovine (npr. portfelj stanova, poslovnih prostora, zemljišta, sportskih objekata, komunalne infrastrukture itd.). Portfelji mogu sadržavati podgrupe odnosno *podportfelje* (npr. kod portfelja *zemljišta* podporfelji mogu biti: građevinsko zemljište, poljoprivredno zemljište itd.).

PRLS - u Republici Hrvatskoj je od 2001. do 2007. za potrebe Vlade implementiran projekt Reforme lokalne samouprave (PRLS) kojeg je razvio *The Urban Institute* iz Washingtona, po narudžbi USAID-a. Cilj je projekta bio ojačati upravljačke kapacitete lokalne samouprave kroz pet modula: (1) upravljanje financijama, (2) upravljanje imovinom, (3) gospodarski razvoj, (4) sudjelovanje građana i (5) informacijski sustavi. Model "Upravljanje imovinom" cjelovito je sagledavao upravljanje – od popisa imovine (inventura), analize statusa vlasništva i

klasifikacije svih pojavnih oblika, prije svega nekretnina, do procjene tržišne vrijednosti nekretnina i učinkovitosti upravljanja mjerene stopom kapitalizacije.

RICS - Royal Institution of Chartered Surveyors, Kraljevska ustanova ovlaštenih procjenitelja.

standardnim uvjetima koji su zadani na nacionalnoj razini. U financijski kapacitet osim potencijalnih poreznih spadaju i potencijalni neporezni prihodi.

Vijeće Europe – međunarodna organizacija s 47 europskih država članica sa sjedištem u Strasbourgu. Osnovana je 5. svibnja 1949. radi zaštite ljudskih prava i jačanja demokracije i pravne države na europskim prostorima.

ŽIVOTOPIS

dr.sc. Marko Ignjatović, mag.oec.
MBA

Kontakt:
Rudeška cesta 246, Zagreb
mob. +385 98 9769 565
marko.ignjatovic@outlook.hr

Deset godina rada na projektima digitalne transformacije različitih tipova organizacija i upravljanja nekretninama u lokalnoj samoupravi, kroz suradnju s velikim brojem lokalnih i regionalnih samouprava, nevladinih organizacija, državnih institucija i međunarodnih korporacija.

Radno iskustvo

Direktor

LIBUSOFT CICOM d.o.o. siječanj 2019. – danas

Opis posla:

- Organizacija i koordinacija svih segmenata poslovanja (financije, prodaja, marketing, pravo, kadrovi, implementacija i razvoj)
- Konzultantska edukacija i trening korisnika (Upravljanje imovinom JLRPS i Lokalni porezi)
- Implementacija projekata održivog razvoja i jačanja javne uprave
- Suradnja s nevladinim organizacijama: Udruga gradova, Hrvatska zajednica županija, UNDP, Institut za javne financije, Institut za javnu upravu, Centar za lokalni ekonomski razvoj, EDA BiH
- Istraživanje i analiza poslovnih mogućnosti
- Definiranje dugoročnih strateških razvoja
- Nastup na konferencijama i seminarima
- Ugovaranje i održavanje suradnje s partnerima

Stručna služba Udruge

Udruga UPRAVITELJ, Zagreb rujan 2012. – danas

Opis posla:

- Planiranje aktivnosti rada Udruge
- Organizacija i koordinacija tijela Udruge
- Organizacija susreta upravitelja
- Razvoj djelatnosti upravljanja nekretninama kroz suradnju s Ministarstvima i Fondom

Pomoćnik direktora
LIBUSOFT CICOM d.o.o. rujan 2010. – prosinac 2018
Opis posla:

- Organizacija i koordinacija svih segmenata poslovanja (financije, prodaja, marketing, pravo, kadrovi, implementacija i razvoj)
- Konzultantska edukacija i trening korisnika (Upravljanje imovinom JLRPS i Lokalni porezi)
- Implementacija projekata održivog razvoja i jačanja javne uprave
- Suradnja sa nevladinim organizacijama: Udruga gradova, Hrvatska zajednica županija, UNDP, Institut za javne financije, Institut za javnu upravu, Centar za lokalni ekonomski razvoj, EDA BiH
- Istraživanje i analiza poslovnih mogućnosti
- Pregovaranje i upravljanje timom
- Nastup na konferencijama i seminarima
- Razvoj novih usluga i proizvoda
- Prodajne aktivnosti i briga o ključnim korisnicima
- Ugovaranje i održavanje suradnje s partnerima

Voditelj Odjela marketinga i prodaje
LIBUSOFT CICOM d.o.o. listopad 2009. – kolovoz 2010.
Opis posla:

- Koordinacija i praćenje rada tima
- Planiranje i realizacija svih marketinških i promotivnih aktivnosti
- Razvijanje strategije i poslovnog plana prodaje
- Konzultantska edukacija i trening korisnika (Upravljanje imovinom JLRPS i Lokalni porezi)
- Odgovornost za realizaciju tima i rezultate
- Prezentacija i prodaja proizvoda i usluga ključnim korisnicima
- Briga o kvaliteti usluge i razini zadovoljstva korisnika
- Praćenje rada konkurentskih tvrtki
- Obilasci korisnika
- Priprema ponuda, natječajne dokumentacije i ugovora

Specijalist prodaje
LIBUSOFT CICOM d.o.o. siječanj 2008. – rujan 2010.
Opis posla:

- Prezentacija i prodaja proizvoda i usluga korisnicima
- Planiranje i izvršenje prodajnog plana
- Briga o kvaliteti usluge i razini zadovoljstva korisnika
- Praćenje rada konkurentskih tvrtki
- Obilasci korisnika

- Priprema ponuda, natječajne dokumentacije i ugovora

Stručna predavanja i radovi

Porez na nekretnine: u čemu je problem? Porezna konferencija, Ekonomski fakultet u Zagrebu, Zagreb, siječanj 2018.

Iskustva u implementaciji poreza na nekretnine. Okrugli stol na temu poreza na nekretnine, Hrvatska gospodarska komora, Zagreb, prosinac 2017.

Kako do većih prihoda nakon ukidanja poreza na nekretnine? Konferencija 48sati gradonačelnika, Udruga gradova i Lider, Vodice, studeni 2017.

Identifikacija poreznih obveznika i nekretnina te ažuriranje evidencija. Primjena zakona o lokalnim porezima, Udruga gradova, Zagreb, veljača 2017.

Izazovi upravljanja imovinom lokalnih jedinica. Građani, javna uprava, lokalna samouprava: Jesu li mogući povjerenje, suradnja i potpora, Institut za javnu upravu, Zagreb, siječanj 2017.

Kako lokalna samouprava upravlja svojim nekretninama? Savjetovanje pročelnika JLP(R)S – Rješenja za efikasnu samoupravu, Udruga gradova, Hrvatska zajednica županija i LC, Zagreb, rujan 2016.

Izazovi upravljanja imovinom lokalnih jedinica. Ekonomski fakultet, Zagreb, svibanj 2015.

Sustav upravljanja imovinom kao bitan preduvjet za brži lokalni ekonomski razvoj. Planiranje, organizacija i provedba investicijskih projekata u lokalnim samoupravama, Centar za lokalni ekonomski razvoj EFRI, Šibenik, rujan 2014.

Local Government Asset Management. NALAS International Municipal Fair, NALAS, Rijeka, rujan 2013.

Informacije – Resurs koji generira bolje prihode i gospodarenje imovinom tijela s javnim ovlastima. Kongres službenika za informiranje, Futurist, Zagreb, listopad 2010.

Kako do stvarnog stanja evidencija nekretnina u JLS i kako njima uspješno upravljati? Savjetovanje o lokalnoj samoupravi, Udruga gradova, Rabac, srpanj 2016.

Znanstveni radovi u zbornicima skupova s međunarodnom recenzijom

Ignjatović, M. (2017). Izazovi upravljanja imovinom lokalnih jedinica. *Građani, javna uprava i lokalna samouprava: povjerenje, suradnja i potpora/urednici: Ivan Koprić, Anamarija Musa, Teo Giljević. Zagreb: Institut za javnu upravu*, 503-520.

Obajava članka u međunarodno priznatom znanstvenom časopisu

Ignjatović, M. (2020). Odrednice uspješnosti povrata na nekretnine u vlasništvu gradova Republike Hrvatske. Hrvatska i komparativna javna uprava: časopis za teoriju i praksu javne uprave.

Obrazovanje i osposobljavanje

Doktorski studij siječanj 2015. – sviban 2020

Ekonomski fakultet, Sveučilište u Zagrebu

Agent za posredovanje u prometu nekretninama lipanj 2016.
Hrvatska gospodarska komora

ISMS interni auditor ISO 27001 i ISO9001 veljača 2013. – travanj 2013.
SGS Adriatica Zagreb i PSI d.o.o. Zagreb

Master of Business Administration (MBA) veljača 2011. – listopad 2012.
Zagrebačka škola ekonomije i managementa, Zagreb

Magistar ekonomije rujan 2003. – lipanj 2009.
Ekonomski fakultet, Sveučilište u Zagrebu

Srednja škola rujan 2000. – lipanj 2003.
IX Gimnazija, Zagreb

Stručno usavršavanje

2017. – **Procjena vrijednosti nekretnina**, Ministarstvo graditeljstva i prostornog uređenja
2017. – **Razvojni program za voditelje timova**, AngloAdria Zagreb
2017. – **Pravna pitanja vezana uz tržište nekretnina**, Hrvatski institut za javne financije Zagreb
2016. – **Procjena vrijednosti nekretnina**, HDSV Zagreb
2016. – **Uspješno vođenje tima**, AngloAndria Zagreb
2016. – **Metode procjene vrijednosti nekretnina**, Hrvatski institut za javne financije Zagreb
2015. – **Academic workshop**, Managerial and Organizational Cognition Division, Dubrovnik
2012. – **NLP trening**, Ramiro d.o.o. Zagreb
2010. – **Executive trening**, Ramiro d.o.o. Zagreb