UTVRĐIVANJE ČIMBENIKA NEPLAĆANJA OBVEZA GRADOVA U REPUBLICI HRVATSKOJ

Krmpotić, David

Doctoral thesis / Disertacija

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Economics in Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Ekonomski fakultet u Osijeku**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:145:904764

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-17**

EFOS Ekonomski fakultet u Osijeku

Repository / Repozitorij:

EFOS REPOSITORY - Repository of the Faculty of Economics in Osijek

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

dabar DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište Josipa Jurja Strossmayera u Osijeku
Ekonomski fakultet u Osijeku
Poslijediplomski doktorski studij Management

David Krmpotić

UTVRĐIVANJE ČIMBENIKA NEPLAĆANJA OBVEZA GRADOVA U REPUBLICI HRVATSKOJ

DOKTORSKA DISERTACIJA

Osijek, 2021.

Sveučilište Josipa Jurja Strossmayera u Osijeku
Ekonomski fakultet u Osijeku
Poslijediplomski doktorski studij Management

David Krmpotić

UTVRĐIVANJE ČIMBENIKA NEPLAĆANJA OBVEZA GRADOVA U REPUBLICI HRVATSKOJ

DOKTORSKA DISERTACIJA

Mentor: izv. prof. dr. sc. Domagoj Karačić

Osijek, 2021.

Josip Juraj Strossmayer University of Osijek
Faculty of Economics in Osijek
Postgraduate doctoral study of *Management*

David Krmpotić

DETERMINING DEFAULT FACTORS OF THE CITIES IN THE REPUBLIC OF CROATIA

DOCTORAL THESIS

Mentor: Associate Professor Domagoj Karačić, Ph. D.

Osijek, 2021.

IZJAVA O AKADEMSKOJ ČESTITOSTI,
PRAVU PRIJENOSA INTELEKTUALNOG VLASNIŠTVA,
SUGLASNOSTI ZA OBJAVU U INSTITUCIJSKIM REPOZITORIJIMA
I ISTOVJETNOSTI DIGITALNE I TISKANE VERZIJE RADA

1. Kojom izjavljujem i svojim potpisom potvrđujem kako je doktorski rad isključivo rezultat osobnoga rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu. Potvrđujem poštivanje nepovredivosti autorstva te točno citiranje radova drugih autora i referiranje na njih.
2. Kojom izjavljujem da je Ekonomski fakultet u Osijeku, bez naknade u vremenski i teritorijalno neograničenom opsegu, nositelj svih prava intelektualnoga vlasništva u odnosu na navedeni rad pod licencom *Creative Commons Imenovanje - Nekomercijalno - Dijeli pod istim uvjetima 3.0 Hrvatska.*
3. Kojom izjavljujem kako sam suglasan da se trajno pohrani i objavi moj rad u institucijskom digitalnom repozitoriju Ekonomskoga fakulteta u Osijeku, repozitoriju Sveučilišta Josipa Jurja Strossmayera u Osijeku te javno dostupnom repozitoriju Nacionalne i sveučilišne knjižnice u Zagrebu (u skladu s odredbama Zakona o znanstvenoj djelatnosti i visokom obrazovanju, NN br. 123/03, 198/03, 105/04, 174/04, 02/07, 46/07, 45/09, 63/11, 94/13, 139/13, 101/14, 60/15).
4. Izjavljujem da sam autor predanog rada i da je sadržaj predane elektroničke datoteke u potpunosti istovjetan s dovršenom tiskanom verzijom rada predanom u svrhu obrane istog.

Ime i prezime studenta: David Krmpotić

Matični broj studenta: 191

OIB: 36897176705

e-mail za kontakt: david.krmpotic@osijek.hr

Naziv studija: Poslijediplomski doktorski studij *Management*

Naslov rada: *Utvrđivanje čimbenika neplaćanja obveza gradova u Republici Hrvatskoj*

Mentor rada: izv. prof. dr. sc. Domagoj Karačić

U Osijeku, 19. studenoga 2021. godine

Potpis

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku
Ekonomski fakultet u Osijeku
Znanstveno područje: društvene znanosti
Znanstveno polje: ekonomija

Doktorska disertacija

UTVRĐIVANJE ČIMBENIKA NEPLAĆANJA OBVEZA GRADOVA U REPUBLICI HRVATSKOJ

David Krmpotić

Disertacija je izrađena u: Osijeku
Mentor: izv. prof. dr. sc. Domagoj Karačić

Kratak sažetak doktorske disertacije

U okvirima izučavanja javnog sektora i institucionalnih subjekata jednu od najvažnijih uloga u funkcioniranju javnog sektora kao i održavanja javnog sustava imaju gradovi. Važnost gradova u Republici Hrvatskoj proizlazi iz činjenice da su gradovi (127 gradova i Grad Zagreb kao jedinica s posebnim statusom) u 2018. godini potrošili 17,9 milijardi kuna na svoje rashode, što u odnosu na rashode državnog proračuna (129,6 milijardi u istoj godini) ukazuje na financijski kapacitet i ulogu gradova u javnom sektoru. Bez obzira na sigurne i stabilne izvore financiranja, tijekom 2018. godine 116 gradova u Republici Hrvatskoj imalo je 684 milijuna kuna dospjelih, neplaćenih obveza. Upravo utvrđivanje čimbenika koji utječu na nemogućnost plaćanja dospjelih obveza gradova u Republici Hrvatskoj predstavlja osnovni cilj analize i istraživanja ove doktorske disertacije. S obzirom da u Republici Hrvatskoj ne postoji zakonska mogućnost stečaja gradova i da se stečajni postupak najčešće provodi zbog dugotrajne nemogućnosti plaćanja obveza u doktorskoj disertaciji nije bilo moguće istraživati koje varijable utječu na stečaj gradova. U provedenim istraživanjima korištena je zamjenska (zavisna) varijabla kreirana putem omjera dospjelih, neplaćenih obveza i ukupnih rashoda i izdataka (*default_proxy*). Temeljem dosadašnjih znanstvenih spoznaja te dostupnih podataka za sve gradove u Republici Hrvatskoj kreiran je set podataka za 33 nezavisne varijable, koje su podijeljene u tri skupine (financije i proračun, likvidnost i dug, stanovništvo), a čiji je utjecaj testiran na kretanje zavisne varijable u vremenskom razdoblju od 2014. do 2018. godine. Ključna je značajka ovoga istraživanja u praćenju dinamike kretanja različitih varijabla kroz

petogodišnje vremensko razdoblje. Korištenjem različitih statističkih metoda izdvojeno je sedam statistički značajnih čimbenika, pri čemu je kreiran višestruki regresijski model temeljen na tri nezavisne varijable. Varijable preneseni manjak prihoda, potraživanja za prihode poslovanja te omjer kratkotrajne imovine i kratkoročnih obveza imaju najveću snagu u objašnjenju varijacija zavisnih varijabla. Prediktivna sposobnost modela značajna je te odabrane nezavisne varijable višestrukog regresijskog modela objašnjavaju 60,1% varijacija zavisne varijable. Predstavljena jednadžba za izračun buduće vrijednosti prosječnog omjera dospjelih neplaćenih obaveza u ukupnim rashodima i izdacima (*default_proxy'*) omogućava jednostavno aplikativno rješenje koje može poslužiti kao sustav ranog upozorenja svim gradovima, ali i nadležnom ministarstvu te kreditorima. Kako bi se smanjile dospjele, neplaćene obaveze gradova, nužno je da čelnici gradova racionalnije upravljaju svojom likvidnošću i proračunskim sredstvima, da zakonodavna i izvršna vlast poboljšaju postojeći zakonodavni okvir, te u konačnici da se izrade i koriste kreditni rejtinzi gradova. Također, ažurniji i sveobuhvatniji, primarno gospodarski, podaci omogućit će budućim istraživačima dodatno usavršavanje predstavljenog modela.

Broj stranica: 288
Broj slika: 20
Broj tablica: 84
Broj literaturnih navoda: 203
Jezik izvornika: hrvatski jezik
Ključne riječi: gradovi, proračun, čimbenici neplaćanja obveza, zaduženost, kreditni rejting.
Datum obrane: 19. studenoga 2021. godine

Stručno povjerenstvo za obranu:
1. prof. dr. sc. Branimir Marković, predsjednik
2. prof. dr. sc. Josipa Mijoč, član
3. izv. prof. dr. sc. Marko Primorac, član
4. prof. dr. sc. Marija Ham, zamjenik člana

Disertacija je pohranjena u: Nacionalnoj i sveučilišnoj knjižnici Zagreb, Ul. Hrvatske bratske zajednice 4, Zagreb; Gradskoj i sveučilišnoj knjižnici Osijek, Europska avenija 24, Osijek; Sveučilištu Josipa Jurja Strossmayera u Osijeku, Trg sv. Trojstva 3, Osijek; Ekonomskom fakultetu u Osijeku, Trg Lj. Gaja 7, Osijek.

BASIC DOCUMENTATION CARD

Josip Juraj Strossmayer University of Osijek PhD thesis
Faculty of Economics in Osijek
Scientific Area: Social Sciences
Scientific Field: Economy

DETERMINING DEFAULT FACTORS OF THE CITIES IN THE REPUBLIC OF CROATIA

David Krmpotić

Thesis performed at: Osijek

Supervisor: Associate Professor Domagoj Karačić, Ph. D.

Short abstract

Within the framework of studying the public sector and institutional entities cities have one of the most important roles in the functioning of the public sector, as well as in the maintenance of the public system. The importance of cities in the Republic of Croatia stems from the fact that in year 2018 cities (127 cities and the City of Zagreb as a unit with a special status) spent HRK 17.9 billion on their expenditures, what, in relation to state budget expenditures (129.6 billion in the same year), indicates the financial capacity and the role of cities in the public sector. Regardless of secure and stable sources of financing during 2018, 116 cities in the Republic of Croatia had HRK 684 million in overdue, unpaid liabilities. Determining the factors that affect the inability to pay due obligations, e.g. default factors, of cities in the Republic of Croatia is the main objective of the analysis and research of this doctoral thesis. Because of the fact that in the Republic of Croatia there is no legal possibility of bankruptcy of cities and that bankruptcy proceedings are most often carried out due to long-term inability to pay obligations, further research on variables that affect the bankruptcy of cities was not possible in this doctoral thesis. The conducted research used a replacement (dependent) variable created through the ratio of overdue, unpaid liabilities and total expenses and expenditures (*default_proxy*). Based on previous scientific knowledge and available data for all cities in the Republic of Croatia, a set of data was created for 33 independent variables, which are divided into three groups (finance and budget, liquidity and debt, population), and whose impact was tested on the

dependent variable in time period from year 2014 to year 2018. A key feature of this study is in monitoring the dynamics of the movement of different variables over a five-year period. Using different statistical methods, seven statistically significant factors were singled out, creating a multiple regression model based on three independent variables. The variables of transferred revenue shortfall, of operating income receivables and the ratio of current assets to current liabilities have the greatest strength in explaining the variations of the dependent variables. The predictive ability of the model is significant, and the selected independent variables of the multiple regression model explain 60.1% of the variations of the dependent variable. The presented equation for calculating the future value of the average ratio of overdue liabilities in total expenditures and expenditures (*default_proxy* ') provides a simple application solution that can serve as an early warning system for all cities, but also for the relevant ministry and creditors. In order to reduce overdue, unpaid liabilities of cities, it is necessary that city leaders manage their liquidity and budget funds more rationally, that the legislature and the executive improve the existing legislative framework, and finally, that credit ratings of cities are created and used. Also, more up-to-date and comprehensive, primarily economic, data will enable future researchers to refine the presented model further.

Number of pages: 288
Number of figures: 20
Number of tables: 84
Number of references: 203
Original in: Croatian language
Key words: cities, budget, non-payment/default factors, indebtedness, credit rating.
Date of the thesis defense: November 19, 2021.

Reviewers:
1. Branimir Marković, Ph. D., president
2. Josipa Mijoč, Ph. D., member
3. Marko Primorac, Ph. D., member
4. Marija Ham, Ph. D., substitute member

Thesis deposited in: National and University Library in Zagreb, Ul. Hrvatske bratske zajednice 4, Zagreb; City and University Library of Osijek, Europska avenija 24, Osijek; Josip Juraj Strossmayer University of Osijek, Trg sv. Trojstva 3, Osijek; Faculty of Economics in Osijek, Trg Lj. Gaja 7, Osijek.

UTVRĐIVANJE ČIMBENIKA NEPLAĆANJA OBVEZA GRADOVA U REPUBLICI HRVATSKOJ

SAŽETAK

U okvirima izučavanja javnog sektora i institucionalnih subjekata jednu od najvažnijih uloga u funkcioniranju javnog sektora kao i održavanja javnog sustava imaju gradovi. Važnost gradova u Republici Hrvatskoj proizlazi iz činjenice da su gradovi (127 gradova i Grad Zagreb kao jedinica s posebnim statusom) u 2018. godini potrošili 17,9 milijardi kuna na svoje rashode, što u odnosu na rashode državnog proračuna (129,6 milijardi u istoj godini) ukazuje na financijski kapacitet i ulogu gradova u javnom sektoru. Bez obzira na sigurne i stabilne izvore financiranja, tijekom 2018. godine 116 gradova u Republici Hrvatskoj imalo je 684 milijuna kuna dospjelih, neplaćenih obveza. Upravo utvrđivanje čimbenika koji utječu na nemogućnost plaćanja dospjelih obveza gradova u Republici Hrvatskoj predstavlja osnovni cilj analize i istraživanja ove doktorske disertacije. S obzirom da u Republici Hrvatskoj ne postoji zakonska mogućnost stečaja gradova i da se stečajni postupak najčešće provodi zbog dugotrajne nemogućnosti plaćanja obveza u doktorskoj disertaciji nije bilo moguće istraživati koje varijable utječu na stečaj gradova. U provedenim istraživanjima korištena je zamjenska (zavisna) varijabla kreirana putem omjera dospjelih, neplaćenih obveza i ukupnih rashoda i izdataka (*default_proxy*). Temeljem dosadašnjih znanstvenih spoznaja te dostupnih podataka za sve gradove u Republici Hrvatskoj kreiran je set podataka za 33 nezavisne varijable, koje su podijeljene u tri skupine (financije i proračun, likvidnost i dug, stanovništvo), a čiji je utjecaj testiran na kretanje zavisne varijable u vremenskom razdoblju od 2014. do 2018. godine. Ključna je značajka ovoga istraživanja u praćenju dinamike kretanja različitih varijabla kroz petogodišnje vremensko razdoblje. Korištenjem različitih statističkih metoda izdvojeno je sedam statistički značajnih čimbenika, pri čemu je kreiran višestruki regresijski model temeljen na tri nezavisne varijable. Varijable preneseni manjak prihoda, potraživanja za prihode poslovanja te omjer kratkotrajne imovine i kratkoročnih obveza imaju najveću snagu u objašnjenju varijacija zavisnih varijabla. Prediktivna sposobnost modela značajna je te odabrane nezavisne varijable višestrukog regresijskog modela objašnjavaju 60,1% varijacija zavisne varijable. Predstavljena jednadžba za izračun buduće vrijednosti prosječnog omjera dospjelih neplaćenih obaveza u ukupnim rashodima i izdacima (*default_proxy'*) omogućava jednostavno aplikativno rješenje koje može poslužiti kao sustav ranog upozorenja svim gradovima, ali i nadležnom ministarstvu te kreditorima. Kako bi se smanjile dospjele, neplaćene

obaveze gradova, nužno je da čelnici gradova racionalnije upravljaju svojom likvidnošću i proračunskim sredstvima, da zakonodavna i izvršna vlast poboljšaju postojeći zakonodavni okvir, te u konačnici da se izrade i koriste kreditni rejtinzi gradova. Također, ažurniji i sveobuhvatniji, primarno gospodarski, podaci omogućit će budućim istraživačima dodatno usavršavanje predstavljenog modela.

Ključne riječi: gradovi, proračun, čimbenici neplaćanja obveza, zaduženost, kreditni rejting.

DETERMINING DEFAULT FACTORS OF THE CITIES IN THE REPUBLIC OF CROATIA

ABSTRACT

Within the framework of studying the public sector and institutional entities cities have one of the most important roles in the functioning of the public sector, as well as in the maintenance of the public system. The importance of cities in the Republic of Croatia stems from the fact that in year 2018 cities (127 cities and the City of Zagreb as a unit with a special status) spent HRK 17.9 billion on their expenditures, what, in relation to state budget expenditures (129.6 billion in the same year), indicates the financial capacity and the role of cities in the public sector. Regardless of secure and stable sources of financing during 2018, 116 cities in the Republic of Croatia had HRK 684 million in overdue, unpaid liabilities. Determining the factors that affect the inability to pay due obligations, e.g. default factors, of cities in the Republic of Croatia is the main objective of the analysis and research of this doctoral thesis. Because of the fact that in the Republic of Croatia there is no legal possibility of bankruptcy of cities and that bankruptcy proceedings are most often carried out due to long-term inability to pay obligations, further research on variables that affect the bankruptcy of cities was not possible in this doctoral thesis. The conducted research used a replacement (dependent) variable created through the ratio of overdue, unpaid liabilities and total expenses and expenditures (*default_proxy*). Based on previous scientific knowledge and available data for all cities in the Republic of Croatia, a set of data was created for 33 independent variables, which are divided into three groups (finance and budget, liquidity and debt, population), and whose impact was tested on the dependent variable in time period from year 2014 to year 2018. A key feature of this study is in monitoring the dynamics of the movement of different variables over a five-year period. Using different statistical methods, seven statistically significant factors were singled out, creating a multiple regression model based on three independent variables. The variables of transferred revenue shortfall, of operating income receivables and the ratio of current assets to current liabilities have the greatest strength in explaining the variations of the dependent variables. The predictive ability of the model is significant, and the selected independent variables of the multiple regression model explain 60.1% of the variations of the dependent variable. The presented equation for calculating the future value of the average ratio of overdue liabilities in total expenditures and expenditures (*default_proxy* ') provides a simple application solution that can serve as an early warning system for all cities, but also for the relevant ministry

and creditors. In order to reduce overdue, unpaid liabilities of cities, it is necessary that city leaders manage their liquidity and budget funds more rationally, that the legislature and the executive improve the existing legislative framework, and finally, that credit ratings of cities are created and used. Also, more up-to-date and comprehensive, primarily economic, data will enable future researchers to refine the presented model further.

Key words: cities, budget, non-payment factors, indebtedness, credit rating.

Mojoj obitelji.

SADRŽAJ

1. Uvod ... 1
1.1. Određivanje problema istraživanja ... 3
1.2. Ciljevi i hipoteze istraživanja ... 7
1.3. Metode znanstvenog istraživanja ... 9
1.4. Sadržaj i struktura rada ... 10
2. Institucionalni i zakonodavni okvir gradova u Republici Hrvatskoj ... 12
2.1. Struktura javnog sektora u Republici Hrvatskoj ... 12
2.2. Institucionalni i zakonodavni okvir gradova ... 15
2.2.1. Administrativno ustrojstvo gradova ... 16
2.2.2. Izvori financiranja gradova ... 21
2.2.2.1. Prirez ... 26
2.2.2.2. Porez na potrošnju ... 28
2.2.2.3. Porez na kuće za odmor ... 28
2.2.2.4. Porez na korištenje javnih površina ... 28
2.2.2.5. Ostali porezni prihodi ... 30
2.2.3. Europska povelja o lokalnoj samoupravi ... 30
3. Proračun i dug gradova ... 32
3.1. Proračun ... 32
3.1.1. Struktura proračuna i proračunske klasifikacije ... 33
3.1.2. Postupak donošenja proračuna ... 41
3.1.3. Proračunska transparentnost ... 49
3.1.4. Proračun i fiskalna politika ... 50
3.2. Obveze i odrednice vjerojatnosti neplaćanja ... 53
3.2.1. Financijske i nefinancijske obveze ... 57
3.2.2. Dospjele i nedospjele obveze ... 58
3.3. Zaduživanje i dug ... 60

3.3.1. Vrste zaduživanja 60
3.3.2. Rizici zaduživanja 67
3.3.3. Instrumenti osiguranja kod zaduživanja 70
3.3.4. Proces i aktivnosti zaduživanja na primjeru gradova 71
3.3.5. Otplata kreditnih obveza i municipalnih obveznica 78
3.3.6. Refinanciranje i reprogramiranje duga 79
4. Čimbenici vjerojatnosti neplaćanja i kreditni rejting 81
4.1. Kreditni rejting 81
4.1.1. Povijesni pregled kreditnog rejtinga 82
4.1.2. Rejting agencije 87
4.1.3. Kretanje kreditnog rejtinga Republike Hrvatske i Grada Zagreba 100
4.1.4. Kreditni rejting i transparentnost 105
4.2. Kredit *scoring* kao dio kreditnog rejtinga 105
4.3. Okvir mjerenja čimbenika neplaćanja dospjelih obveza gradova 108
4.3.1. Suvremene znanstvene spoznaje o čimbenicima neplaćanja dospjelih obveza 109
4.3.2. Čimbenici koji utječu na nemogućnost plaćanja obveza u Republici Hrvatskoj 112
5. Financijska i socioekonomska pozicija gradova od 2014. do 2018. godine 115
5.1. Prihodi i rashodi gradova u Republici Hrvatskoj 115
5.2. Imovina i obveze gradova u Republici Hrvatskoj 127
5.3. Zaduženost gradova u Republici Hrvatskoj 134
5.4. Ostali socioekonomski pokazatelji gradova u Republici Hrvatskoj 140
5.4.1. Procjena kretanja broja stanovnika po gradovima 142
5.4.2. Broj zaposlenih i nezaposlenih 143
5.4.3. Indeks razvijenosti 145
5.4.4. Ocjena transparentnosti gradova 148
6. Metodologija istraživanja 151

6.1. Metodologija prikupljanja podataka 152
6.2. Okvir uzorka 152
6.3. Operacionalizacija varijablā 155
6.3.1. Zavisna varijabla 160
6.3.2. Nezavisne varijable 161
6.3.2.1. Financije i proračun 161
6.3.2.2. Likvidnost i dug 163
6.3.2.3. Stanovništvo 166
6.4. Metode analize podataka 167
7. Rezultati empirijskog istraživanja 171
7.1. Analiza čimbenika neplaćanja obveza gradova 171
7.1.1. Deskriptivna analiza zavisne i nezavisnih varijablā 171
7.1.2. T-test nezavisnih uzoraka 181
7.1.3. Korelacijska analiza 181
7.1.4. Analiza varijance zavisnih podataka 189
7.1.5. Ispitivanje odnosa među varijablama primjenom regresijske analize na panel-podatcima 199
7.1.5.1. Financije i proračun 199
7.1.5.2. Likvidnost i dug 201
7.1.5.3. Stanovništvo 205
7.1.6. Oblikovanje modela za izračun nemogućnosti plaćanja obveza gradova (analiza latentne krivulje rasta) 206
7.2. Rasprava o rezultatima istraživanja 220
7.2.1. Ograničenja i nedostatci modela za predviđanje nemogućnosti plaćanja obveza gradova 225
7.3. Preporuke i smjernice za buduća istraživanja 226
7.3.1. Preporuke proizašle iz modela 226
7.3.1.1. Preporuke za zakonodavnu i izvršnu vlast 227

7.3.1.2. Preporuke za lokalnu samoupravu ... 229
7.3.1.3. Preporuke za financijske institucije ... 229
7.3.2. Smjernice za buduća istraživanja ... 230
8. Zaključak ... 231
Literatura ... 235
Popis tablica ... 251
Popis slika ... 255
Popis grafikona ... 256
Popis kratica ... 257
Prilog 1. Dospjele nepodmirene obveze gradova od 2014. do 2018. godine (u 000 kuna) ... 259
Prilog 2. Ukupni rashodi i izdatci gradova od 2014. do 2018. godine (u 000 kuna) ... 262
Prilog 3. Nemogućnost plaćanja dospjelih obveza (*default_proxy*) od 2014. do 2018. godine (uređenje prema uzlaznoj vrijednosti varijable u 2018. godini) ... 265
Prilog 4. Kretanje procijenjenog broj stanovnika gradova od 2014. do 2018. godine ... 268
Prilog 5. Bonfferonijev post-hoc test ... 271
Prilog 6. Detaljni prikaz modeliranja *početne vrijednosti (intercept)* ... 279
Prilog 7. Detaljni prikaz modeliranja *dinamike kretanja (slope)* ... 282
Prilog 8. Detaljni prikaz konačnog modela ... 285
Životopis autora ... 287

1. Uvod

Gradovi zauzimaju značajno mjesto u javnom sektoru te su nositelji velikog broja ključnih funkcija važnih za živote stanovnika, ali i za kvalitetnije funkcioniranje države kao cjeline. Primarni je cilj zakonodavca, ali i svih sudionika koji upravljaju gradovima, osigurati visoku razinu kvalitete života brigom za stanovnike, ali i izgradnjom i održavanjem infrastrukture koja se nalazi na području svakoga grada. Briga za stanovnike očituje se u brojnim aktivnostima i programima vezanim uz: predškolsko i osnovnoškolsko obrazovanje, socijalno ugrožene, umirovljenike, razvoj poduzetništva, kulturu i sport te zaštitu života i zdravlja građana. Opskrba pitkom vodom, odvodnja, gradski prijevoz, čistoća te odvoz smeća predstavljaju komunalne aktivnosti koje su povjerene gradovima s ciljem brige za svoje stanovnike. Gradovi brinu za infrastrukturu i infrastrukturne projekte potrebne za obavljanje svih navedenih aktivnosti, ali brinu i o svim javnim površinama (trgovi i parkovi), cestama, mostovima, javnoj rasvjeti i odlagalištima otpada. Gradovi upravljaju i imovinom velike vrijednosti odnosno, velikim brojem vlastitih zgrada, stanova i poslovnih prostora. Sve navedene funkcije i odgovornosti dane gradovima potrebno je dobro isplanirati u skladu s izvorima financiranja i proračunskim mogućnostima.

Struktura prihoda gradova može se podijeliti na porezne, neporezne i ostale prihode. Najveći i najznačajniji prihodi proračuna gradova dolaze od poreznih prihoda, od kojih je financijski najznačajniji prihod od poreza na dohodak. Manje su značajni porezni prihodi gradova prirez porezu na dohodak, porez na potrošnju i porez na promet nekretnina. S obzirom na to da gradovi nemaju mogućnost određivanja i utjecaja na visinu stope poreza na dohodak ili poreza na promet nekretnina, vidljivo je gradovi imaju vrlo nisku razinu fiskalne fleksibilnosti u odlučivanju o poreznim prihodima. Drugi najvažniji prihodi koji omogućavaju gradovima financiranje aktivnosti i programa su komunalni prihodi gdje kroz komunalnu naknadu i komunalni doprinos gradovi financiraju izgradnju i održavanje komunalne infrastrukture, dok se prihodima od spomeničke rente u pojedinim gradovima može financirati održavanje kulturnih dobara. Ostali manje značajni izvori prihoda za gradove su koncesije za različite vrste djelatnosti koje su povjerene privatnicima, a to su: koncesije za parking, dimnjačarske usluge ili koncesije na pomorskim dobrima. Uz porezne i neporezne prihode, gradovi mogu ostvarivati prihode i različitim vrstama zaduživanja pri čemu se primitcima od dugoročnog zaduživanja mogu financirati važni infrastrukturni projekti te izgradnja objekata nužnih za obavljanje osnovnih gradskih funkcija.

Dodatno, o važnosti gradova u javnom sektoru govori činjenica kako su najveća zaduženja jedinica lokalne i regionalne (područne) samouprave u 2018. godini, vezana za gradove i iznose preko 80 % ukupnog duga.

Najveći izazov, ali i ključnu obvezu temeljem fiskalne odgovornosti, u procesima upravljanja gradovima predstavlja proces uravnoteženja proračunskih prihoda i rashoda, odnosno pravilno raspolaganje povjerenim sredstvima građana. Budući da je u Republici Hrvatskoj lokalna samouprava jako *usitnjena* te da postoji 428 općina i 128 gradova uključujući i Grad Zagreb, razvidno je kako postoje velike razlike u stupnju razvijenosti gradova te samim time i u fiskalnim kapacitetima proračuna gradova. Kako bi se omogućio ravnomjeran razvoj svih lokalnih jedinica, država putem sredstava fiskalnog izravnanja pomaže manje razvijenim lokalnim jedinicama (do kraja 2020. godine to su činili razvijeni gradovi). Unatoč tome, postoje gradovi koji nemaju uravnotežen proračun te troše više nego što prihoduju, što ima za posljedicu negativan financijski rezultat i neplaćanje preuzetih obveza na vrijeme i u punom iznosu. Iako je plaćanje obveza na vrijeme regulirano zakonom[1], postoji čak 116 gradova u Republici Hrvatskoj koji su na kraju 2018. godine imali dospjele, neplaćene obveze u ukupnom iznosu od preko 684 milijuna kuna. Dospjele obveze mogu biti rezultat neadekvatnog upravljanja proračunom i financijama, ali isto tako i rezultat nelikvidnosti ili prezaduženosti. Dodatno, gospodarski i socijalni pokazatelji mogu utjecati na nemogućnost plaćanja obveza gradova. Kombinacija navedenih čimbenika može dovesti do kratkotrajne, ali i dugotrajne nemogućnosti plaćanja obveza i upravo razina dospjelih obveza predstavlja jedan od važnijih pokazatelja velikih financijskih poteškoća kod gradova.

Poslovanje i financijske aktivnosti svakoga grada predmetom su nadzora više subjekata. Nadziru ga građani putem javno dostupnih podataka te članovi predstavničkog tijela prigodom rasprave o izvršavanju proračuna za svaku proračunsku godinu. Nadzire ga Ministarstvo financija putem Izjave o fiskalnoj odgovornosti ili prilikom davanja suglasnosti Ministra ili Vlade Republike Hrvatske povodom dugoročnog zaduživanja, a povremeno rad i financijske aktivnosti gradova nadzire i Državni ured za reviziju. Isto tako nadzor rada svake gradske uprave obavljaju i financijske institucije, u prvom redu banke, kao najveći kreditori. Naime, na kraju 2018. godine, u strukturi bilance, 99 gradova imalo je prikazane obveze za kredite i zajmove, dok je kumulativni dug svih tih gradova iznosio preko 3,4 milijarde kuna.

[1] Zakon o financijskom poslovanju i predstečajnoj nagodbi (Narodne novine 108/2012, 144/2012, 81/2013, 112/2013, 78/2015 i 71/2015).

Taj iznos dodatno uvećavaju obveze gradova po izdanim vrijednosnim papirima (npr. obveznice), zatim po izdanim jamstvima za kredite, ali i obveze po kreditima ustanovama kojima su gradovi osnivači kao i krediti poduzeća u vlasništvu gradova.

Financiranje gradova, iz perspektive bankarskog ili financijskog sektora, putem kredita ili ulaganja u vrijednosne papire u Republici Hrvatskoj i ostalim državama širom svijeta predstavlja posao niskog rizika. Iako je kreditni rizik takvog posla nizak, svi sudionici financijskog tržišta konzervativno procjenjuju uvjete financiranja kako bi odredili cijenu po kojoj će posuditi svoj novac. Bajo i suradnici (2011) navode da je kvaliteta i vjerodostojnost dužnika, odnosno njegova kreditna (ne)sposobnost od iznimne važnosti kod zaduživanja te da se kreditna sposobnost može okarakterizirati kao stanje u kojem je kreditni rizik dužnika (za vjerovnika) prihvatljiv ili minimalan. Kreditni je rizik jedan od najvažnijih faktora u procesu zaduživanja između obje strane. Banke i ostali sudionici financijskog tržišta koriste čitav niz kvantitativnih i kvalitativnih pokazatelja kako bi utvrdili stupanj rizika koji nosi financiranje nekoga grada te im dodjeljuju svoje *rejtinge*. Osim njih, analizu poslovanja gradova u svijetu provode i kreditne rejting agencije. Nažalost, ne postoji sistematiziran izračun i javni prikaz rejtinga za sve gradove u Republici Hrvatskoj koji bi omogućio usporedbu gradova prema riziku zaduženosti i ispunjavanju financijskih obveza, ali i na jasan način ukazao čelnicima gradova kojim se aktivnostima navedena rizičnost može smanjiti. Postoji nužnost uvođenja ocjene kreditne sposobnosti kroz sustav kreditnog rejtinga kako bi se poboljšala kontrola, ali i - *pravilnije određivali prioriteti u odobravanju zaduživanja lokalnih jedinica* (Bajo, Primorac, 2010). U Republici Hrvatskoj najveće međunarodne kreditne rejting agencije provjeravale su samo poslovanje Grada Zagreba te je zasad Grad Zagreb jedini grad kojeg su kreditne rejting agencije i ocijenile.

1.1. Određivanje problema istraživanja

Kreditori procjenjuju vjerojatnost da će gradovi svoje buduće obveze ispuniti na vrijeme i u punom iznosu. Unatoč niskom riziku, odnosno maloj vjerojatnosti da se to neće dogoditi, postoji niz gradova u Republici Hrvatskoj, ali i diljem svijeta, koji su ušli u financijske poteškoće, a najveći i najpoznatiji je možda slučaj bankrota grada Detroita u SAD-u (proglašen 2013. godine). Primjerice, u Italiji u razdoblju od 2000. godine do 2012. godine 32 lokalne jedinice proglasile su bankrot sukladno njihovom zakonu (Gregori, Marattin 2017: 1274). Povremeno se i gradovi u Republici Hrvatskoj nađu u situaciji da ne mogu platiti svoje obveze pa im računi budu blokirani od strane vjerovnika.

Neki od gradova koji su bili u takvoj situaciji su: Osijek (2009.), Dubrovnik (2013.), Omiš (2014.), Ploče (2017.) i Knin (2017.). Tim gradovima nije, kao u drugim državama svijeta, prijetio stečaj jer temeljem Stečajnog zakona[2] u Republici Hrvatskoj zakonski nije moguće provesti stečaj na jedinicama lokalne i područne (regionalne) samouprave, ali neovisno o tome određeno su vrijeme bili u financijskim poteškoćama.

Kako bi se takve situacije prevenirale te kako bi gradovi dodatno smanjili rizik za svoje kreditore, ali i sve ostale čije se aktivnosti financiraju ili plaćaju proračunskim sredstvima, važno je znati koji su čimbenici povezani s neplaćanjem dospjelih obveza gradova. Identifikacija čimbenika i analiza elemenata neplaćanja gradova predstavljaju osnovu istraživačkog problema koji se u doktorskoj disertaciji istražuje. Iako se financijske institucije koriste i kvalitativnim pokazateljima kod kvantificiranja rizika gradova, u doktorskoj disertaciji fokus je usmjeren na istraživanje kvantitativnih čimbenika. Nemogućnost ispunjenja obveza na vrijeme i u punom iznosu kod gradova u Republici Hrvatskoj očituje se ponajprije putem bilančnih pozicija dospjelih, neplaćenih obveza, pri čemu postoji čitav niz varijablā čiji utjecaj može značajno narušiti financijsku stabilnost. Primarno postoje sljedeće vrste čimbenika:

- financijski čimbenici (utjecaj određene stavke prihoda, rashoda ili bilance)
- ekonomski čimbenici (utjecaj izvoza, BDP-a, nezaposlenosti i sl.)
- populacijski čimbenici (utjecaj strukture i kretanja broja stanovnika)
- politički čimbenici (utjecaj političkih stranaka, trenutka u izbornom ciklusu i sl.).

U literaturi postoje brojna istraživanja koja su analizirala poteškoće u financijskom poslovanju i odrednice nemogućnosti plaćanja trgovačkih društava, dok je značajno manje obrađenih istraživanja koja istražuju poteškoće i odrednice nemogućnosti plaćanja lokalnih jedinica. Brojnim istraživanjima, koja predstavljaju ishodišnu točku istraživanja ove doktorske disertacije, zajedničko je da je testirano od svega nekoliko pa do čak 40 različitih nezavisnih varijablā kao i njihov utjecaj na nemogućnost plaćanja lokalnih jedinica.

Svi istraživači testiraju financijske varijable vezane za strukturu proračunskih prihoda i razinu duga. Važno je napomenuti da su Holian i Joffe (2013), uz navedeno, testirali i godišnju promjenu prihoda. Cohen i suradnici (2011) testiranju su pridodali i primljene pomoći po stanovniku, a Janda i Moreira (2016) državne transfere prema promatranim lokalnim jedinicama.

[2] Stečajni zakon (Narodne novine 71/2015 i 104/2017), članak 3., stavak 2.

Uz osnovne financijske varijable, Errais (2019) testirao je i dodatne financijske informacije kao što su prosječna kamatna stopa ili prosječno vrijeme do dospijeća duga. Benito i Bastida (2004: 498) podijelili su prethodna, teorijska i empirijska istraživanja zaduženosti lokalnih jedinica u tri skupine: efikasnost nametnutih limita zaduživanja, rejting duga lokalnih jedinica te faktori koji utječu na volumen duga. Njihovo istraživanje fokusiralo se na posljednju skupinu.

Značajan je broj istraživača koji su testirali i utjecaj ekonomskih i populacijskih varijablā. Radi se o utjecaju izvoza, bruto domaćeg proizvoda, zaposlenih i nezaposlenih radno sposobnih stanovnika te uzimanja u omjer raznih varijablā s brojem stanovnika pojedine lokalne jedinice. Kao dodatni pokazatelj iz ove skupine Hajek i Hajkova (2009) koristili su koncentraciju lokalne ekonomije, a Navarro-Galera i suradnici (2015) koristili su broj ekonomski ovisnog stanovništva.

Svega nekoliko istraživača koristilo je i političke varijable od kojih su Hajek i Hajkova (2009) tome dali najveći značaj. Oni su testirali utjecaj pojedine faze u izbornom ciklusu, zatim indeks političke podijeljenosti te utjecaj većine jedne političke stranke u predstavničkom tijelu. Navarro-Galera i suradnici (2015) testirali su utjecaj političkog predznaka, dok su Posedel i Primorac (2011) testirali utjecaj političke povezanosti središnje vlasti i lokalnih jedinica.

U spomenutim istraživačkim studijama, u najvećoj mjeri, primjenjivale su se različite vrste regresijske analize. Tako su Hajek i Hajkova (2009) koristili linearnu regresijsku analizu, binarnu regresiju koristili su Gregori i Marattin (2017), a Tobit regresiju koristili su Posedel i Primorac (2012). Primorac i Vlah-Jerić (2017) testirali su učinke tri različite metode analize podataka: umjetnu neuronsku mrežu, hibridnu umjetnu neuronsku mrežu i pristup genetskog algoritma te Tobit regresija u određivanju kreditnog rizika. Logit regresiju koristili su Holian i Joffe (2013), Navarro-Galera (2015), zatim Janda i Moreira (2016), te Errais (2019). Uz Logit regresiju, Palumbo i suradnici (2006) koristili su Probit model te običnu metodu najmanjih kvadrata. Gorina i suradnici (2018) koristili su relogit (engl. *rare events logostic regression*) model.

Postoje značajne razlike između pojedinih istraživača po pitanju broja analizom obuhvaćenih lokalnih jedinica te promatranog razdoblja. Obuhvat istraživanja sužen je s obzirom na već provedena istraživanja, odnosno na činjenicu da je povezanost financijskih i ekonomskih čimbenika s neplaćanjem obveza najznačajnija za izračun rizičnosti gradova.

Identifikacija ključnih financijskih i ekonomskih čimbenika gradova problem je gradova te se u doktorskoj disertaciji njemu pristupa primjenom regresijske analize panel-podataka. U tablici br. 1 nalazi se pregled najznačajnijih istraživanja korištenih u ovoj disertaciji.

Tablica 1. Pregled istraživača i veličine uzorka istraživanja

Naziv istraživača	Godina	Država	Uzorak	Promatrano razdoblje
Errais, E.	2019.	Tunis	264 lokalne jedinice	2010. - 2016.
Gorina, E.; Joffe, M. i Maher, C.	2018.	SAD	2 100 lokalne jedinice	2007. - 2016.
Primorac, M.; Vlah-Jerić, S.	2017.	Hrvatska	556 općina, gradova i županija	2008.
Gregori, W. D.; Marattin, L.	2017.	Italija	32 lokalne jedinice koje su bankrotirale	2000. - 2012.
Janda K.; Moreira, D.	2016.	Portugal	299 lokalnih jedinica	2014.
Navarro-Galera, A.; Lara-Rubio, J.; Buendia Carrillo, D.; Rayo Canton, S.	2015.	Španjolska	148 gradova	2008. - 2011.
Holian, M. J.; Joffe, M. D.	2013.	SAD	>260 gradova	2011. - 2012.
Posedel, P.; Primorac, M.	2012.	Hrvatska	556 općina, gradova i županija	2008.
Cohen, S.; Doumpos, M.; Neophytou, E.; Zapounidis, C.	2011.	Grčka	360 lokalnih jedinica	2007.
Hajek, P.; Hajkova, V.	2009.	Češka	452 lokalne jedinice	2002. - 2006.
Palumbo, G.; Shick, R.; Zaporowski, M.	2006.	SAD	159 izdanih obveznica lokalnih jedinica	1986. - 1995.

Izvor: Sistematizirao autor temeljem dostupne znanstvene literature

Svrha je doktorske disertacije **utvrđivanje čimbenika neplaćanja obveza gradova u Republici Hrvatskoj**. Rezultati analize čimbenika neplaćanja obveza gradova omogućit će primarno sudionicima financijskog tržišta, zatim različitim razinama vlasti (samim gradovima, županijama, Ministarstvu financija, Vladi Republike Hrvatske), kreditnim rejting agencijama i javnosti kvalitetniju spoznaju i relevantnije informacije o rizičnosti, odnosno bonitetu gradova.

1.2. Ciljevi i hipoteze istraživanja

Ciljevi doktorske disertacije mogu se podijeliti u dvije skupine ciljeva, a to su - teorijski i empirijski ciljevi.

Teorijski ciljevi doktorske disertacije usmjereni su na:

1. analizu i interpretaciju prethodnih istraživanja te sveobuhvatne, relevantne literature
2. analizu i detaljan teorijski pregled sljedećih područja kroz:
    a. institucionalni i zakonodavni okvir vezan za sustav funkcioniranja lokalnih jedinica te izradu proračuna i zaduživanje gradova
    b. kreditni rejting i odrednice vjerojatnosti neplaćanja
3. izradu prijedloga modela za predviđanje nemogućnosti plaćanja obveza gradova u Republici Hrvatskoj.

Empirijski ciljevi doktorske disertacije usmjereni su na:

1. analizu i obradu financijskih pozicija gradova u Republici Hrvatskoj temeljem dostupnih podataka Ministarstva financija o prihodima, rashodima te bilanci gradova
2. determiniranje čimbenika koji su najviše povezani s neplaćanjem obveza gradova
3. utvrđivanje osnovnih parametara koji određuju kreditnu sposobnost i odgovarajuću stopu zaduženosti svakog grada u Republici Hrvatskoj
4. prijedlog i testiranje prediktivne sposobnosti modela za predviđanje nemogućnosti plaćanja obveza gradova u Republici Hrvatskoj.

Osnovni cilj doktorske disertacije polazi od identificiranja i testiranja svih relevantnih financijskih i socioekonomskih čimbenika te izdvajanja ključnih varijablā koje su statistički značajno povezane s neplaćanjem obveza gradova. Nadalje, temeljem pretpostavljenog modela predviđa se mogućnost evaluacije pozicija gradova u Republici Hrvatskoj prema rasponu, od početne vrijednosti neplaćenog duga uz brzinu i smjer promjene tog duga gradova sukladno analiziranim i odabranim podatcima za vremensko razdoblje od 2014. do 2018. godine.

Zaključno, predviđa se tijekom analize prethodnih i provedenih istraživanja razviti regresijski model za predviđanje nemogućnost plaćanja dospjelih obveza gradova u Republici Hrvatskoj gradova.

Hipoteze istraživanja

Na temelju definiranih osnovnih i ostalih ciljeva istraživanja definirane su sljedeće hipoteze:

- **H1 –** Karakteristike financija i proračuna gradova statistički su značajno povezane s neplaćanjem dospjelih obveza gradova.
- **H2 –** Karakteristike likvidnosti i duga gradova statistički su značajno povezane s neplaćanjem dospjelih obveza gradova.
- **H3 –** Socioekonomske karakteristike gradova statistički su značajno povezane s neplaćanjem dospjelih obveza gradova.
- **H4 –** Veliki gradovi imaju statistički značajno manju izloženost za nemogućnost plaćanja od ostalih gradova u Republici Hrvatskoj.

Hipoteze **H1 do H3** postavljene su s namjerom testiranja povezanosti u korelaciji korištenja tri skupine čimbenika kao što su: financije i proračun, likvidnost i dug te ostali socioekonomski čimbenici. Predloženi čimbenici predstavljaju i nezavisne varijable u procesu oblikovanja modela, ali i zavisne varijable s obzirom na to da nastoje obuhvatiti cjelokupni segment analize svih aspekata neplaćanja dospjelih obveza gradova u Republici Hrvatskoj.

Hipotezom **H1** testira se povezanost varijablā u formi koeficijenata, koji primarno sadrže prihodovne i rashodovne stavke proračuna analiziranih gradova dok se hipotezom **H2** nastoji testirati povezanost varijablā koje u najvećoj mjeri sadrže bilančne pozicije, odnosno uključuju prikaz imovine i obveza gradova, a koje predstavljaju jednu od najvažnijih stavki financijskog potencijala gradova.

Hipotezom **H3** testira se statistička povezanost između nekoliko različitih socioekonomskih pokazatelja**.** Kategorija socioekonomskih pokazatelja gradova uključuje sljedeće najvažnije pokazatelje kao što su: kretanje stanovništva, fluktuacija zaposlenosti stanovništva te transparentnost izvješćivanja i ponašanja gradova u okvirima poslovanja i pružanja lokalnih javnih usluga.

Hipotezom **H4** testira se povezanost veličine grada u odnosu na neplaćanje obveza. Naime, velikim se gradovima u Republici Hrvatskoj, sukladno Zakonu[3], smatraju - *jedinice lokalne samouprave koje su ujedno gospodarska, financijska, kulturna, zdravstvena, prometna i znanstvena središta razvitka šireg okruženja i koji imaju više od 35 000 stanovnika* (Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, čl. 19. a). Prema podatcima iz popisa stanovništva obavljenog 2011. godine, takvih je gradova u Republici Hrvatskoj bilo svega 17 (od ukupno 128 gradova), ali u njima živi preko 1,8 milijuna ljudi, odnosno preko 43 % ukupnog stanovništva Republike Hrvatske. To su gradovi koji prednjače po vrijednosti imovine kojom raspolažu, ali i po vrijednosti i raznovrsnosti prikupljenih prihoda i zato imaju važno mjesto u analizi usporedbe različitih veličina gradova u odnosu na nemogućnosti plaćanja obveza. Zakonom o lokalnoj i područnoj (regionalnoj) samoupravi ovlasti velikih gradova dane su i gradovima sjedištima županija koji nisu svojim brojem stanovnika zadovoljili uvjet veličine te trenutno postoji osam takvih gradova u Republici Hrvatskoj s ukupno 167 043 stanovnika.

1.3. Metode znanstvenog istraživanja

U prvom dijelu rada, u kojem je naglasak doktorske disertacije usmjeren na teorijsku razradu uloge grada u sustavu javnog upravljanja, upravljanja proračunom i zaduživanjem te važnošću kreditnog rejtinga u odnosu na procjenu boniteta gradova, koriste se primarno metode analize i sinteze. Daljnje metode koje se koriste za potrebe istraživanja i pisanja doktorske disertacije su: induktivna i deduktivna metoda, metoda generalizacije i specijalizacije, klasifikacije, komparacije te deskriptivna metoda. U poglavlju vezanom za financijsku poziciju gradova koriste se primarno metode računovodstvene i financijske analize. Koristi se i metoda dokazivanja kao i komparativna metoda. U empirijskom dijelu rada primjenjuju se statističke i matematičke metode, prije svega korelacijske i regresijske analize panel-podataka koje su, prema prethodnim istraživačkim studijama, smatraju prikladnim statističkim instrumentarijem za testiranje postavljenih hipoteza doktorske disertacije. Dodatno, koriste se i analiza latentnog rasta krivulje te višestruki hijerarhijski regresijski model. Kvantitativni podatci, prikupljeni iz javno dostupnih izvora, organizirani su u datoteku prikladnu za analizu podataka uz računalnu podršku programa *MS Excel, IBM SPSS Statistics 25 i Mplus 8.1.*

[3] Zakon o lokalnoj i područnoj (regionalnoj) samoupravi (Narodne novine 33/2001, 60/2001, 129/2005, 109/2007, 36/2009, 125/2008, 36/2009, 150/2011, 144/2012, 123/2017, 98/19).

U analizi podataka koriste se univarijatne statističke metode (mjere središnje tendencije, disperzije, asimetrije i mjera zaobljenosti), bivarijatne statističke metode (t-test nezavisnih uzoraka, korelacijska analiza) te multivarijatne statističke metode (regresijska analiza panel-podataka, standardizirani beta-ponderi, analiza latentnog rasta krivulje, procjena parametara robusnom *maximum likelihood* procjenom, višestruka hijerarhijska regresijska analiza).

Očekivani znanstveni doprinos u ***teorijskom smislu*** proizlazi iz razvijanja znanstvenih spoznaja vezanih za financijsko upravljanje lokalnim jedinicama kao važnim oblikom ostvarivanja kvalitetnijih ekonomskih i financijskih aspekata upravljanja u odnosu na stajališta ostvarivanja kreditne i financijske sposobnosti. Značajan znanstveni doprinos sastoji se i od pregleda domaće i strane stručne i znanstvene literature te sistematiziranog pregleda recentnih dosadašnjih istraživanja koja su provedena u velikim europskim državama (Italija, Španjolska, Grčka, Turska) te ostalim odabranim zemljama. Glavni doprinos ogleda se u prijedlogu modela predviđanja neplaćanja obveza gradova u Republici Hrvatskoj. Naime, temeljem utvrđenih, ključnih čimbenika neplaćanja obveza kreiran je model koji može determinirati koeficijent rizika svakom pojedinom gradu, sukladno analiziranim kategorijama plaćanja i neplaćanja obveza. Očekivani doprinos ekonomskoj znanosti u ***aplikativnom smislu*** sastoji se od identificiranja ključnih financijskih i socioekonomskih čimbenika te izrade modela za izračun nemogućnosti plaćanja obveza gradova. Budući da dosadašnja istraživanja u Republici Hrvatskoj nisu obuhvaćala vremenske serije odnosno višegodišnja razdoblja, doprinos ove doktorske disertacije usmjeren je na konkretne mogućnosti definiranja povezanosti navedenih čimbenika s neplaćanjem obveza gradova u Republici Hrvatskoj. Empirijski i metodološki okvir doktorske disertacije polazi od rezultata koji obuhvaćaju prošireni obuhvat nezavisnih varijablā, a koje su u testiranju hipoteza podijeljene u tri sljedeće skupine: financije i proračun, likvidnost i dug te stanovništvo (socioekonomske varijable). U konačnici, doktorskom disertacijom omogućava se buduća procjena rizičnost i financijske izloženost svakog grada, što omogućuje kasniju međusobnu usporedbu gradova te usporedbu zaduženosti i boniteta gradova u Republici Hrvatskoj.

1.4. Sadržaj i struktura rada

Doktorska disertacija sastoji se od osam osnovnih dijelova. U **uvodnom** dijelu disertacije prikazana je struktura same disertacije, definiran je problem istraživanja te su prikazani osnovni ciljevi, hipoteze istraživanja kao i primijenjene metode znanstvenog istraživanja.

Struktura javnog sektora te položaj gradova u navedenom sustavu razrađeni su u **drugom dijelu** disertacije. Također, obrađen je cjelokupni zakonodavni okvir kojim se definira uloga gradova, ali i način funkcioniranja, financiranja i autonomija koja im je dana. Zbog specifične uloge i važnosti velikih gradova za funkcioniranje javnog sektora, zasebno se analiziraju u većem dijelu disertacije.

Treći dio disertacije pod nazivom *Proračun i dug gradova* podijeljen je u tri dijela. U prvom dijelu detaljno je prikazana struktura proračuna, proračunska načela i klasifikacije te postupak njegova donošenja. U drugom je dijelu prikazana i objašnjena povezanost čimbenika vjerojatnosti neplaćanja i obveza. U trećem dijelu prikazan je proces zaduživanje gradova, zatim rizici koji ga prate kao i načini refinanciranja i reprogramiranja duga.

U **četvrtom** dijelu dan je detaljan prikaz povijesnog razvoja kreditnog rejtinga te uloga rejtinga agencija. Analizirani su čimbenici koje velike rejting agencije koriste prilikom ocjenjivanja lokalnih jedinica, zatim kretanje rejtinga Republike Hrvatske i Grada Zagreba te kredit *scoringa* kao važan alata prilikom izračuna kreditnog rejtinga. U završnom dijelu ovog poglavlja, sistematizirani su čimbenici koji utječu na vjerojatnost neplaćanja.

Financijskoj poziciji gradova u Republici Hrvatskoj posvećen je **peti dio** doktorske disertacije. Detaljno je razrađena i analizirana struktura prihoda, rashoda i obveza gradova u Republici Hrvatskoj kao i svi aspekti analize duga i zaduženost gradova. Dodatno su analizirani i ostali socioekonomski pokazatelji gradova kao što je kretanje broja stanovnika i broj nezaposlenih.

U **šestom dijelu** disertacije prikazana je i objašnjena metodologija istraživanja te okvir uzorka korištenog u disertaciji. Nadalje, prikazan je i način kreiranja zavisne varijable te kreiranje i grupiranje nezavisnih varijablā.

Sedmi dio disertacije rezerviran je za rezultate empirijskog istraživanja. Dan je detaljan opis faza i provedbe istraživanja od deskriptivne analize, preko korelacijskih analiza pa sve do ekonometrijske analize te oblikovanja modela za izračun nemogućnosti plaćanja obveza gradova. U završnom dijelu ovog poglavlja obrazložene su smjernice za buduća istraživanja te preporuke svim dionicima.

Završni dio doktorske disertacije posvećen je sažetom prikazu najvažnijih rezultata i zaključaka ovoga rada.

2. Institucionalni i zakonodavni okvir gradova u Republici Hrvatskoj

Javni je sektor vrlo širok pojam koji obuhvaća sve aspekte ekonomskog funkcioniranja jedne države odnosno, može se definirati kao *dio ekonomije koji sačinjavaju sve razine vlasti i uz njih javna društva* (Encyclopedia Britannica Online[4]). Svaka država ima svoja pravila kojima ustrojava pojedinu razni vlasti, a ni Republika Hrvatska nije iznimka. Primjerice uloga gradova u funkcioniranju države jasno je definirana odnosno definirane su različite ovlasti i odgovornosti dane gradovima, kao ključnoj razni javnog upravljanja. Odgovornost koja je ključna za ovu doktorsku disertaciju je odgovornost za pravodobno podmirenje svojih obveza.

2.1. Struktura javnog sektora u Republici Hrvatskoj

Javni sektor obuhvaća državu na svim razinama, središnju banku, razne državne fondove i agencije te poduzeća u državnom vlasništvu (Jurković 2002: 14). Javni sektor ne obuhvaća ništa što nije pod direktnim upravljanjem države kao što su privatna poduzeća, kućanstva i dobrovoljne organizacije. Također, zakon kaže da su to *državni proračun, jedinice lokalne i područne (regionalne) samouprave, proračunski i izvanproračunski korisnici državnog proračuna i proračuna jedinica lokalne i područne (regionalne) samouprave* (Zakon o proračunu[5], čl. 3.), a na slici br. 1 prikazana je podjela javnog sektora.

Slika 1. Hrvatski javni sektor

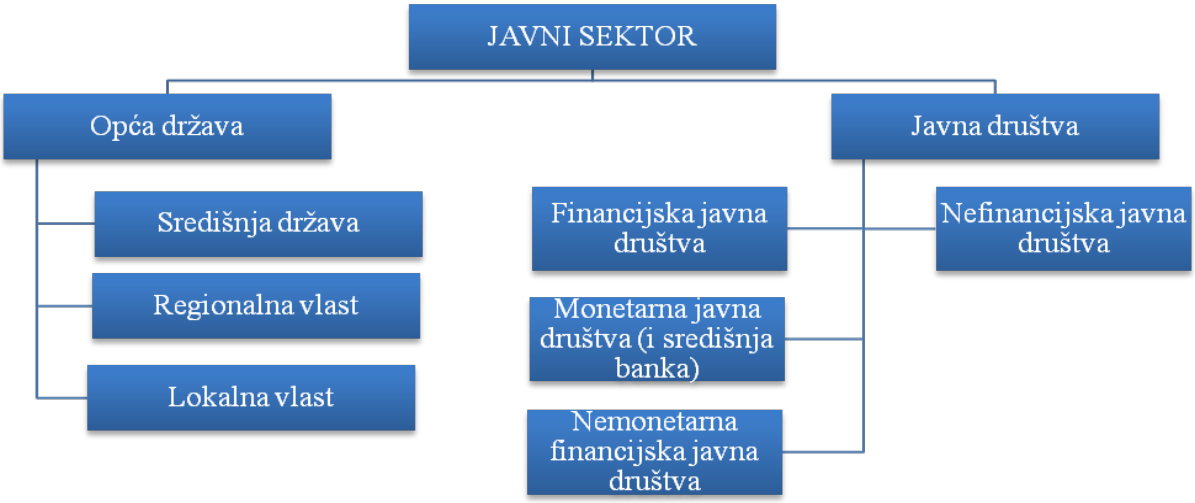

Izvor: Bajo, A. i Jurlina Alibegović, D. (2008). Javne financije lokalnih jedinica vlasti. Školska knjiga. Zagreb.

[4] http://www.britannica.com/topic/public-sector (pristupljeno: 17. listopada 2019.).
[5] Zakon o proračunu (Narodne novine 87/08, 109/07, 136/12, 15/15).

Sektor opće države čine sve državne jedinice i neprofitne institucije koje kontrolira i uglavnom financira država (Bajo, Jurlina Alibegović 2008: 2). Najvišu razinu fiskalne vlasti, prema istim autorima, čini središnja država, odnosno podsektor opće države. Drugu razinu čini regionalna vlast, odnosno županije i Grad Zagreb kao jedinica s posebnim statusom[6] (vlastitim je zakonom dobio status županije, ali i poslove iz djelokruga grada i županije). Treću razinu čine lokalne jedinice vlasti koje se sastoje od gradova i općina. Ovakva podjela javnog sektora predstavlja osnovu pojma decentralizacije. Država, putem raznih zakonskih rješenja, centralizira i integrira upravljanje nekim procesima ili ih decentralizira odnosno prepušta nižim oblicima vlasti. *Decentralizacija je sredstvo vertikalne diobe vlasti i ograničenja političke moći i organizacijski model povećanja učinkovitosti javne uprave* (Kregar, J. i suradnici 2011: 1). U Republici Hrvatskoj značajne su ovlasti i odgovornosti dodijeljene nižim razinama vlasti koje ne čine samo navedene tri osnovne razine, nego i čitav sustav korisnika prikazan na slici 2. Želja zakonodavca za decentralizacijom s ciljem povećanja učinkovitosti odražava se približavanjem vlasti krajnjim korisnicima, a to su ponajprije građani, ali i sve pravne osobe s nekog područja, s ciljem bržeg rješavanja problema i boljeg prepoznavanja budućih potreba.

Slika 2. Javni sektor i njegove osnovne komponente

Izvor: Prikaz autora na temelju podataka Međunarodnog monetarnog fonda[7]

[6] Zakon o Gradu Zagrebu (Narodne novine 62/01, 125/08, 36/09, 119/14, 98/19).
[7] Government Financial Statistics Manual. 2014. Washington D.C. International Monetary Fund. 20 str.

Bitno je napomenuti kako proračunski korisnici uglavnom postoje i na nižim razinama opće države kao što je, primjerice, slučaj na lokalnoj razini vlasti gdje se u proračunske korisnike obično ubrajaju vrtići, osnovne škole, ustanove za upravljanje sportskim objektima, vatrogasne postrojbe ili ustanove u kulturi. Decentralizacija nije na svim razinama vlasti provedena u jednakoj mjeri. Naime, predškolski odgoj u potpunosti je *prepušten* lokalnim jedinicama vlasti gdje država zakonima uređuje samo osnovne standarde i pravila provođenja samog odgoja. Sve druge odluke, od sredstava financiranja do načina upravljanja u nadležnosti su lokalnih jedinica. Drugi zanimljiv primjer postoji kod osnovnog školstva gdje je država, unatoč činjenici da je nominalno i zakonski škole kao korisnike prenijela u segment ovlasti lokalnih jedinica, zadržala vlastiti sustav financiranja. Primjerice, plaće učitelja u osnovnim školama isplaćuju se direktno iz državnog proračuna, isto tako sredstva za održavanje škola i investicijska ulaganja također definira država i doznačava gradovima, a jedino što je u potpunosti prepušteno školama i njihovim osnivačima je sustav upravljanja (izbor ravnatelja, nastavnog i ostalog osoblja te planovi rada i sl.). Slična, djelomična decentralizacija prisutna je i kod sustava vatrogastva.

Među izvanproračunske korisnike ubrajaju se izvanproračunski fondovi, trgovačka društva (javna poduzeća) i druge pravne osobe u kojima država ima odlučujući utjecaj na upravljanje, izvor financiranja je namjenski prihod i evidentirani su u registru korisnika proračuna (Bajo, Jurlina Alibegović 2008). Izvanproračunski korisnici na razini države su, recimo, Hrvatski zavod za mirovinsko osiguranje, Hrvatski zavod za zapošljavanje, Hrvatski zavod za zdravstveno osiguranje ili Fond za zaštitu okoliša i energetsku učinkovitost[8].

Javna se društva dijele na nefinancijska i financijska javna društva. Hrvatske šume, Hrvatske vode ili Hrvatska elektroprivreda pripadaju u nefinancijska javna društva u vlasništvu Republike Hrvatske. Financijska javna društva mogu se podijeliti na depozitarna i ostala financijska javna društva. Među depozitarna javna društva ubrajaju se *financijske institucije u vlasništvu države poput: Hrvatske narodne banke (HNB), Hrvatske banke za obnovu i razvitak (HBOR), Hrvatske poštanske banke (HPB) i Croatia banke* (Bajo, Jurlina Alibegović 2008: 25). Isti autori, među ostala financijska javna društva ubrajaju *institucije koje obavljaju pomoćne aktivnosti za transakcije vezane za financijsku imovinu i obveze ili transformaciju sredstava, odnosno obavljaju financijsko posredovanje kao glavnu aktivnost* (Bajo, Jurlina Alibegović 2008).

[8] Registar proračunskih i izvanproračunskih korisnika (Narodne novine 68/2015).

Financijska agencija, Središnje klirinško depozitarno društvo, Državna agencija za osiguranje štednih uloga i sanaciju banaka i Hrvatska agencija za nadzor financijskih usluga najznačajnije su institucije tog tipa.

Donošenje odluka u javnom sektoru s dvije ili više razina vlasti, kao što je to u Republici Hrvatskoj, mogućnosti razrezivanja poreza te upotrebe tako prikupljenih sredstava predstavlja dio teorije javnih financija koji se zove fiskalni federalizam (Bajo, Jurlina Alibegović 2008: 32). Fiskalni federalizam razmatra odnos između jedne od gore navedenih razina vlasti i dodijeljenih im javnih funkcija, odnosno razinu decentralizacije javnih ovlasti i fiskalne snage. Daljnja (i potpuna) decentralizacija, primjerice, osnovnog školstva trebala bi sa sobom nositi i financijsko osnaživanje lokalnih jedinica. *Fiskalna decentralizacija predstavlja svojevrstan prijenos fiskalne snage od središnje na regionalne i lokalne razine vlasti za financiranje utvrđenih nadležnosti u ponudi javnih dobara i usluga* (Vukić 2016: 117). U današnje vrijeme razina decentralizacije direktno ovisi o odluci državne vlasti, ali indirektno ovisi i o razini ekonomske razvijenosti s obzirom na to da razvijenija društva teže većoj razini decentralizacije. Važno je napomenuti da su centralizacija i decentralizacija kontinuirani procesi podložni stalnim promjenama i prilagodbama ekonomskih i fiskalnih okolnosti. *Za provedbu fiskalne decentralizacije nužno je postupno povećavati autonomiju lokalnih jedinica u prikupljanju prihoda, a Vlada bi trebala razmotriti proširivanje ili pak ukidanje ograničenja raspona u kojem jedinice lokalne i područne (regionalne) samouprave mogu propisivati stope vlastitih poreza* (Bajo, Primorac 2014). Naravno, fiskalna decentralizacija nosi sa sobom i odgovornost lokalnih jedinica za provedbu svih dodijeljenih javnih ovlasti. Neispunjavanje preuzetnih obveza, bilo da se radi o neprovođenju preuzete funkcije ili o neplaćanju preuzetih obveza, utječe na funkcioniranje cjelokupnog državnog sustava.

2.2. Institucionalni i zakonodavni okvir gradova

Lokalne jedinice vlasti funkcioniraju unutar zakonodavnog okvira kojim se definiraju razine lokalne vlasti, zatim njihovo funkcioniranje i financiranje te u konačnici i zaduživanje. Najvažniji pravni akti koji sačinjavaju taj okvir u Republici Hrvatskoj su: Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, Zakon o financiranju jedinica lokalne i područne (regionalne) samouprave, Zakon o lokalnim porezima, Zakon o porezu na promet nekretnina, Zakon o proračunu, te Europska povelje o lokalnoj samoupravi.

2.2.1. Administrativno ustrojstvo gradova

Zakonom je utvrđeno da su *jedinice lokalne samouprave općine i gradovi, te je utvrđen i njihov djelokrug i ustrojstvo, način rada njihovih tijela te nadzor nad njihovim aktima i radom* (Zakon o lokalnoj i područnoj (regionalnoj) samoupravi[9]).

Visok stupanj decentralizacije sustava u Republici Hrvatskoj vidljiv je kroz nekoliko razina lokalnih i regionalnih jedinica, ali još i više kroz njihov ukupan broj (slika br. 3). Upitna je opravdanost zadržavanja ovoga broja lokalnih jedinica vlasti s obzirom na to da do prije tridesetak godina nisu postojale županije i općina je bilo 102[10], a sustav je bolje i učinkovitije funkcionirao. Stoga Marković i Stojanović (2007) ističu potrebu *okrupnjavanja i stvaranja većih jedinica koje bi imale veći fiskalni kapacitet i koje bi mogle učinkovitije odgovoriti na postavljene zadaće*.

Slika 3. Broj lokalnih jedinica vlasti

Izvor: Prikaz autora na temelju podataka Ministarstva uprave Republike Hrvatske[11]

Gradovi su prije svega urbane, povijesne, prirodne, gospodarske i društvene cjeline. Gradom se definira i *svaka jedinica lokalne samouprave u kojoj je sjedište županije ili svako mjesto koje ima više od 10.000 stanovnika* (Zakon o lokalnoj i područnoj (regionalnoj) samoupravi). Zakon još definira da *u sastav grada kao jedinice lokalne samouprave mogu biti uključena i prigradska naselja koja s gradskim naseljem čine gospodarsku i društvenu cjelinu te su s njim povezana dnevnim migracijskim kretanjima i svakodnevnim potrebama stanovništva od lokalnog značenja* (Zakon o lokalnoj i područnoj (regionalnoj) samoupravi).

[9] Zakon o lokalnoj i područnoj (regionalnoj) samoupravi (Narodne novine 33/2001, 60/2001, 129/2005, 109/2007, 36/2009, 125/2008, 36/2009, 150/2011, 144/2012, 123/2017, 98/19).
[10] Državni zavod za statistiku (2011). *Statistički ljetopis Republike Hrvatske*. http://www.dzs.hr/Hrv_Eng/ljetopis/2011/SLJH2011.pdf (pristupljeno: 4. prosinca 2020.).
[11] https://uprava.gov.hr/o-ministarstvu/ustrojstvo/uprava-za-politicki-sustav-drzavnu-upravu-te-lokalnu-i-podrucnu-regionalnu-samoupravu/lokalna-i-podrucna-regionalna-samouprava/popis-zupanija-gradova-i-opcina/846 (pristupljeno: 9. ožujka 2020.).

S obzirom na to da trenutno u Republici Hrvatskoj postoji 127 gradova (bez grada Zagreba) vidljivo je da su, sukladno zakonu, pojedina mjesta definirana gradom, iako ne zadovoljavaju minimalne zakonske uvjete. Zakon također propisuje posebne razloge, kao što su povijesni, gospodarski ili geoprometni, temeljem kojih se može definirati postojanje nekog grada. Zbog velikog broja gradova, zakonodavac je dodatno apostrofirao *velike gradove*. Riječ je o gradovima koji su *gospodarska, financijska, kulturna, zdravstvena, prometna i znanstvena središta razvitka šireg okruženja i koji imaju više od 35 000 stanovnika* (Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, čl. 19.a). Takvih je gradova 17 (prema tablici br. 2) te je u njima, prema zadnjem provedenom popisu stanovništva, ukupno živjelo 1 851 225 stanovnika. Ti su gradovi osim osnovnih poslova[12], preuzeli i dodatne odgovornosti kao što je *održavanje javnih cesta, izdavanje građevinskih i lokacijskih dozvola, drugih akata vezanih uz gradnju, te provedba dokumenata prostornog uređenja* (Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, čl. 19.a).

Tablica 2. Pregled velikih hrvatskih gradova s više od 35 000 stanovnika

Veliki grad	Broj stanovnika	Udio	Udio u RH
ZAGREB	790 017	42,7 %	18,4 %
SPLIT	178 102	9,6 %	4,2 %
RIJEKA	128 624	6,9 %	3,0 %
OSIJEK	108 048	5,8 %	2,5 %
ZADAR	75 062	4,1 %	1,8 %
VELIKA GORICA	63 517	3,4 %	1,5 %
SLAVONSKI BROD	59 141	3,2 %	1,4 %
PULA	57 460	3,1 %	1,3 %
KARLOVAC	55 705	3,0 %	1,3 %
SISAK	47 768	2,6 %	1,1 %
VARAŽDIN	46 946	2,5 %	1,1 %
ŠIBENIK	46 332	2,5 %	1,1 %
DUBROVNIK	42 615	2,3 %	1,0 %
BJELOVAR	40 276	2,2 %	0,9 %
KAŠTELA	38 667	2,1 %	0,9 %
SAMOBOR	37 633	2,0 %	0,9 %
VINKOVCI	35 312	1,9 %	0,8 %
Ukupno	**1 851 225**	**100,0 %**	**43,2 %**
Ukupan broj stanovnika u RH	**4 284 889**		**100,0 %**

Izvor: Prikaz autora temeljen na podatcima s popisa stanovništva (2011. godine) Državnog zavoda za statistiku[13]

[12] Osnovne odgovornosti definirane zakonom su: *uređenje naselja i stanovanje, prostorno i urbanističko planiranje, komunalno gospodarstvo, briga o djeci, socijalna skrb, primarna zdravstvena zaštita, odgoj i obrazovanje, kultura, tjelesna kultura i šport, zaštita potrošača, zaštita i unaprjeđenje prirodnog okoliša, protupožarna i civilna zaštita, te promet na svom području* (Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, čl. 19.a).

[13] www.dzs.hr (pristupljeno: 11. studenoga 2020.).

Grad Zagreb najveći je grad u Republici Hrvatskoj te je na posljednjem, službenom popisu stanovništva iz 2011. godine brojao 790 017 stanovnika, a udio broja stanovnika u ukupnom broju stanovnika svih velikih gradova iznosio je 42,7 %. Najmanji su na toj listi bili gradovi Samobor i Vinkovci koji su imali tek nešto više stanovnika od spomenutog limita. Ukupno gledajući, više od 43 % stanovnika Republike Hrvatske živi u gradovima većima od 35 000 stanovnika.

Zakonom o lokalnoj i područnoj (regionalnoj) samoupravi ovlasti velikih gradova dane su i gradovima sjedištima županija, a koji imaju manje od 35 000 stanovnika te trenutno postoji 8 takvih gradova u Republici Hrvatskoj s ukupno 167 043 stanovnika (tablica br. 3).

Tablica 3. Veliki gradovi manji od 35 000 stanovnika koji su sjedišta županija

Veliki grad (sjedište županije)	Broj stanovnika	Udio	Udio u RH
KOPRIVNICA	30 854	18,5 %	0,7 %
VUKOVAR	27 683	16,6 %	0,6 %
ČAKOVEC	27 104	16,2 %	0,6 %
POŽEGA	26 248	15,7 %	0,6 %
VIROVITICA	21 291	12,7 %	0,5 %
GOSPIĆ	12 745	7,6 %	0,3 %
KRAPINA	12 480	7,5 %	0,3 %
PAZIN	8 638	5,2 %	0,2 %
Ukupno	**167 043**	**100,0 %**	**3,9 %**
Ukupan broj stanovnika u RH	**4 284 889**		**100,0 %**

Izvor: Izračun autora na temelju podataka s popisa stanovništva (2011. godina) Državnog zavoda za statistiku[14]

Pazin je postao velikim gradom zahvaljujući činjenici da je središte Istarske županije, iako je gotovo upola manji od općine Viškovo koja ima 14 445 stanovnika, odnosno manji je od nekoliko velikih općina[15]. Krmpotić (2015) ističe da bi, s obzirom na ranije spomenute ovlasti velikih gradova, trebalo preispitati postojeća zakonska rješenja i ulogu velikoga grada ipak ograničiti određenim brojem stanovnika. Taj broj stanovnika, odnosno svojevrstan limit, može biti i niži od 35 000, osobito uzimajući u obzir trendove depopulacije gradova od posljednjeg popisa te može obuhvatiti i dio gradova iz tablice br. 3 koji su središta županija, ali ne bi trebao obuhvaćati gradove koji svojom veličinom ne zaslužuju trenutno dodijeljene im uloge.

[14] www.dzs.hr (pristupljeno: 11. studenoga 2020.).
[15] Prema podatcima Državnog zavoda za statistiku s popisa stanovništva 2011. godine, osam je općina veće od Grada Pazina: Viškovo, Nedelišće, Popovača, Čepin, Matulji, Brdovec, Pitomača i Podstrana.

Istim su zakonom definirani proračunski[16] prihodi jedinica lokalne samouprave, a kako je fokus ovoga rada na gradovima izdvojeni su u nastavku samo njihovi prihodi:

1. *gradski porezi, prirez, naknade, doprinosi i pristojbe*
2. *prihodi od stvari u njegovom vlasništvu i imovinskih prava*
3. *prihodi od trgovačkih društava i drugih pravnih osoba u njegovom vlasništvu, odnosno u kojima ima udio ili dionice*
4. *prihodi od naknada za koncesije*
5. *novčane kazne i oduzeta imovinska korist za prekršaje koje sam propiše u skladu sa zakonom*
6. *udio u zajedničkom porezu*
7. *sredstva pomoći Republike Hrvatske predviđena u državnom proračunu*
8. *drugi prihodi određeni zakonom* (Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, čl. 68.).

Unatoč činjenici da se lokalne jedinice u Republici Hrvatskoj značajno razlikuju po svojim karakteristikama te samim tim postoje i velike razlike u strukturi financiranja svake pojedine jedinice, i dalje je moguće zaključiti da, kod većine njih, dominantnu ulogu imaju prihodi s osnove međusobne podjele zajedničkih poreza između općina i županija ili gradova i županija (udio u porezu na dohodak) te od raznih doprinosa i naknada. Tomu treba pridodati i upravne i boravišne pristojbe koje nekim jedinicama, najviše u priobalju, donose značajne prihode. Gradovi ostvaruju prihode i od iznajmljivanja svojih stanova i poslovnih prostora, iznajmljivanja zemljišta (primjerice davanja u zakup građevinskog zemljišta u poljoprivredne svrhe do privođenja zemljišta osnovnoj namjeni) ili naplate prava građenja (dugoročni najam zemljišta s pravom izgradnje objekta na istom). Dodatno, gradovi periodično i prodaju svoje nekretnine. Otkup društvenih stanova započeo je još sredinom devedesetih godina te se prihod dijeli između države i gradova (u omjeru 55 % država, 45 % gradovi[17]), a puno je rjeđa situacija u kojoj gradovi izgrađuju stanove namijenjene prodaji. Značajan prihod gradova predstavljaju prodaje raznih vrsta građevinskih zemljišta kao što su: zemljišta za izgradnju obiteljskih kuća i stambenih zgrada, zemljišta za izgradnju sportske infrastrukture (izgradnja stadiona Nogometnog kluba Osijek) te poslovnih objekata na području gradova (uključujući i poslovne zone).

[16] *Temeljni financijski akt jedinice lokalne i područne (regionalne) samouprave je proračun* (Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, članak 69.).
[17] Zakon o prodaji stanova na kojima postoji stanarsko pravo, članak br. 27.

Prema Krmpotiću (2015), gradovi uglavnom ne koriste prihode od svojih trgovačkih društava (odnosno prihode iz dobiti trgovačkih društava) za financiranje proračunske potrošnje budući da su u vlasništvu lokalnih jedinica uglavnom komunalna poduzeća (lokalni prijevoz putnika, odvoz komunalnog otpada, vodovod i sl.). Takva bi društva trebala imati uravnotežene prihode sa svojim rashodima. Svaki potencijalni višak prihoda nad rashodima trebao bi se uložiti u novu infrastrukturu, povećanje kvalitete pružene usluge ili bi se trebao vratiti građanima kroz smanjenje cijene komunalne usluge.

Zakon definira da je *koncesija pravo koje se stječe ugovorom za gospodarsko korištenje općeg ili drugog dobra, za radove ili usluge te da davatelj koncesije može biti: Hrvatski sabor, Vlada Republike Hrvatske, tijela državne uprave (u ime Republike Hrvatske), nadležna tijela jedinica lokalne i područne (regionalne) samouprave (u ime jedinica lokalne i područne (regionalne) samouprave) te pravne osobe posebnim propisima ovlaštene za davanje koncesija* (Zakon o koncesijama[18]). Koncesije se najčešće daju za *komunalne djelatnosti, za eksploataciju mineralnih sirovina, za korištenje voda, na pomorskom dobru, u području energetike, za obavljanje djelatnosti linijskog i obalnog pomorskog i riječnog prijevoza, za luke, za pružanje usluga javnog prijevoza, za djelatnosti gospodarenja otpadom, u području turizma, za slobodne zone i ostale zakonom predviđene aktivnosti* (Zakon o koncesijama, čl. 8.). Prema Krmpotiću (2015), prihodi od naknada za koncesije kod lokalnih jedinica uglavnom se odnose na koncesije za naplatu parkiranja, dimnjačarske usluge, premještanje i blokiranje nepropisno parkiranih vozila ili distribuciju toplinske energije, lokalne jedinice koje se nalaze u priobalju dodatno koriste mogućnost davanja u koncesiju pomorskoga dobra. Isti autor navodi da se novčane kazne i oduzeta imovinska korist za propisane prekršaje najviše odnose na kazne koje ispisuju prometni i komunalni redari prvenstveno s ciljem zaštite komunalne infrastrukture te nisu veliki izvor prihoda lokalnim jedinicama, ali služe kao poluga za očuvanje reda i smanjenje budućih troškova za održavanje te iste infrastrukture.

Dodatno valja naglasiti da se osim Zakona o lokalnoj i područnoj (regionalnoj) samoupravi, detaljnije ovom problematikom bave Zakon o financiranju jedinica lokalne i područne (regionalne) samouprave te Zakon o lokalnim porezima. Sva tri zakona povezuje način financiranja nižih razina vlasti te je stoga zakonodavac nepotrebno zakomplicirao situaciju kada je jednu materiju podijeliti na tri zakonska rješenja. Uz to, prevelika regulacija ne omogućava adekvatnu fiskalnu fleksibilnost.

[18] Narodne novine 169/2017.

2.2.2. Izvori financiranja gradova

Zastupnički dom Sabora Republike Hrvatske donio je krajem 1993. godine zakon koji se zvao Zakon o financiranju jedinica lokalne samouprave i uprave, a taj se zakon uz određene izmjene primjenjivao sve do kraja 2017. godine. Među svim tim izmjenama dogodile su se, kako ističe Rogić Lugarić - *dvije značajnije normativne promjene sustava financiranja lokalnih i područnih (regionalnih) jedinica*. Prva normativna promjena bila je sudska odluka o ukidanju triju poreza: *poreza na neobrađeno obradivo poljoprivredno zemljište, poreza na nekorištene poduzetničke nekretnine te na neizgrađeno građevinsko zemljište* (odluka Ustavnog suda[19]). Druga je zakonska izmjena (krajem 2006. godine) kojom dotadašnji zajednički porez na dobit postaje isključivi porez središnje države (Rogić Lugarić 2012: 102). Kao što se može vidjeti u tablici br. 4., u posljednjih 25 godina došlo je do značajnih promjena kad su u pitanju izvori financiranja lokalnih jedinica vlasti.

Prilikom prvog strukturiranja izvora financiranja gradova (1994. godine) zakonom su gradovima pripala sredstva od dijela poreza na dohodak, dijela poreza od priređivanja igara na sreću, dijela poreza na dobit te dijela poreza na promet nekretnina. Do danas je ključni prihod gradova ostao prihod od poreza na dohodak, a ovisnost se gradova o tom prihodu povećavala tijekom godina kako je dio drugih poreza postao isključivi prihod države.
Naime, s početnih 25 % (45 % za Grad Zagreb) udio u porezu na dohodak povećan je na 60 %. Udio sredstava poreza na dohodak potrebnih za pokrivanje troškova decentraliziranih funkcija gradova uveden je 2001. godine te se od tada kretao u rasponu od 2,9 % do 4,4 %. Iako je, temeljem Zakona o vatrogastvu[20], udio grada namijenjen financiranju redovne djelatnosti zaposlenika javne vatrogasne postrojbe trebao rasti svake godine 2 % od početne 2002. godine do zaključno 2005. godine, već se sljedeće godine od toga odustalo. Fond za izravnanje uveden je 2001. godine te je tijekom godina udio smanjen s 21 % na 17 %. Porez od priređivanja igara na sreću bio je do 2002. godine porez koji se dijelio između gradova (50 %) i centralne vlasti, kao što je i slučaj s porezom na dobit koji se s centralnom vlasti dijelio sve do 2007. godine.

[19] Narodne novine 26/07. Nekoliko godina nakon donošenja, pokrenut je postupak za ocjenu ustavnosti ovog dijela Zakona. Predlagatelji, Ivan Šimunović iz Zagreba i dr. sc. Božidar Jelčić iz Zagreba, isticali su da *je uvođenje obveze plaćanja poreza na zemljištu koje se ne iskorištava radi stjecanja dohotka ili drugih pogodnosti, suprotno ekonomskim i socijalno-političkim načelima na koja bi se trebao zasnivati porezni sustav neke države* te da *navedeni porezi imaju, prema vlasnicima nekretnina na koje se odnose, obilježje kaznenih poreza, jer je njihova svrha da ih se prisili na činjenje koje nije ni ustavno ni zakonski pravno utemeljeno* (Odluka Ustavnog suda). Ustavni im je sud dao za pravo te ih je svojom odlukom od 21. veljače 2007. godine proglasio neustavnim.
[20] Narodne novine br. 106/1999, 117/2001, 36/2002, 96/2003, 174/2004, 38/2009, 80/2010, 125/2019.

Prihod od poreza na promet nekretnina kontinuirano je sve do 2015. godine pripadao gradovima u udjelu od 60 %, da bi od 2015. godine udio bio povećan na 80 %, a u konačnici i u potpunosti prepušten gradovima u 2018. godini.

Tablica 4. Povijesni pregled vrsta dijeljenih poreznih prihoda lokalnih jedinica i viših razina vlasti od 1994. godine do 2019. godine

Vrsta poreza	**1994.**	**2000.**	**2001.**	**2002.**	**2003.**
Porez na dohodak	25 %	32 %	32 %	32 %	34 %
Porez na dohodak Grad Zagreb	45 %	45 %	45 %	45 %	47 %
Decentralizirane funkcije	-	-	*2,9 %*	*2,9 % + 2 %*	*2,9 % +1 %*
*Fond za izravnanje**	-	-	*21 %*	*21 %*	*21 %*
Porez od priređivanja igara na sreću	50 %	50 %	50 %	-	-
Porez na dobit	20 %	20 %	20 %	20 %	20 %
Porez na dobit Grad Zagreb	30 %	30 %	30 %	30 %	30 %
Porez na promet nekretnina	60 %	60 %	60 %	60 %	60 %
Vrsta poreza	**2007.**	**2008.**	**2012.**	**2015.**	**2018.**
Porez na dohodak	52 %	55 %	56,5 %	60 %	60 %
Porez na dohodak Grad Zagreb	67 %	70,5 %	72,5 %	76,5 %	77 %
Decentralizirane funkcije	*3,1 % + 1,3 %*	*3,1 % + 1,3 %*	*3,1 % + 1,3 %*	*1,9 % + 1 %*	*1,9 % + 1 %*
Fond za izravnanje	*21 %*	*17,5 %*	*15,5 %*	*16 %*	*17 %*
Porez od priređivanja igara na sreću	-	-	-	-	-
Porez na dobit	-	-	-	-	-
Porez na dobit Grad Zagreb	-	-	-	-	-
Porez na promet nekretnina	60 %	60 %	60 %	80 %	100 %**

Izvor: Prikaz autora na temelju povijesnih podataka iz Zakona o financiranju jedinica lokalne i područne (regionalne) samouprave[21]; *Sredstva Fonda koriste sve razine vlasti (županije, gradovi i općine) **
Prihod od poreza na promet nekretnina pripada jedinici lokalne samouprave na području koje se nekretnina nalazi (Zakon o porezu na promet nekretnina).

Jednim dijelom zbog prikazanih, učestalih zakonskih izmjena tijekom godina, ali i zbog novina koje su se uvodile kao što je *jednostavniji, pravedniji i razumljiviji način definiranja sustava raspodjele prihoda od poreza na dohodak, sustava fiskalnog izravnanja jedinica lokalne i područne (regionalne) samouprave te sustava financiranja decentraliziranih funkcija* (Odbor

[21]Narodne novine br. 117/1993, 92/1994, 69/1997, 33/2000, 73/2000, 127/2000, 59/2001, 107/2001, 117/2001, 150/2002, 147/2003, 132/2006, 26/2007, 73/2008, 25/2012, 147/2014, 100/2015, 115/2016, 127/2017, 138/2020.

za financije i državni proračun)[22] početkom 2018. godine na snagu stupa potpuno novi zakon pod nazivom Zakon o financiranju jedinica lokalne i područne (regionalne) samouprave. Ovim se zakonom uređuju *izvori sredstava i financiranje poslova iz samoupravnog djelokruga jedinica lokalne i područne (regionalne) samouprave, raspodjela prihoda od poreza na dohodak, fiskalno izravnanje jedinica lokalne i područne (regionalne) samouprave te financiranje decentraliziranih funkcija* (čl. 1. zakona). Dodatna novina je i da se lokalni porezi uređuju posebnim propisima odnosno Zakonom o lokalnim porezima.

Država je novim zakonom *poslušala* razmišljanja dijela stručne javnosti[23] i u potpunosti prepustila prihod od poreza na dohodak lokalnim jedinicama. *Prihod od poreza na dohodak zajednički je porez te se dijeli između općina, gradova i županija* (tablica br. 5), *a općina, grad, županija i Grad Zagreb, koji prema posebnim propisima financiraju decentralizirane funkcije[24], raspodjeljuju međusobno udio za decentralizirane funkcije* (Zakon o financiranju jedinica lokalne i područne (regionalne) samouprave, čl. 5.).

Tablica 5. Raspodjela poreza na dohodak

Raspodjela poreza na dohodak	Udio (u %)
Udio općine ili grada	74 %
Udio županije	20 %
Udio za decentralizirane funkcije	6 %
Osnovno školstvo	*1,9 %*
Srednje školstvo	*1,3 %*
Socijalnu skrb	*0,8 %*
Zdravstvo	*1 %*
Vatrogastvo (JPVP)	*1 %*
Ukupno	**100 %**

Izvor: Prikaz autora na temelju Zakona o financiranju jedinica lokalne i područne (regionalne) samouprave[25]

Kako bi svi građani imali jednaku mogućnost za školovanje ili zaštitu osnovnih prava, donose se odluke o minimumu potrebnih financijskih sredstava.

[22] https://www.sabor.hr/hr/radna-tijela/odbori-i-povjerenstva/izvjesce-odbora-za-financije-i-drzavni-proracun-o-prijedlogu-515 (pristupljeno: 19. listopada 2019.).

[23] Bajo i Primorac isticali su *da bi država lokalnim jedinicama trebala potpuno prepustiti porez na dohodak koji se prikupi na njihovom prostoru, jer je dijeljenje poreza postalo instrument ublažavanja gospodarskih nejednakosti, financiranja kapitalnih projekata, ali i mehanizam za financiranje decentraliziranih funkcija, a prema njima, višestruka uloga tog instrumenta nije poželjna* (Aktualni osvrt, br. 72, 2014).

[24] Primjerice Grad Osijek, kroz udio za decentralizirane funkcije, financira osnovno školstvo i vatrogastvo (zajedno 2,9 %) dok Osječko-baranjska županija financira srednje školstvo, socijalnu skrb i zdravstvo (3,1 %).

[25] Narodne novine br. 127/2017, 138/2020.

V*lada Republike Hrvatske u odlukama o minimalnim financijskim standardima utvrđuje minimalan iznos sredstava koja je potrebno osigurati za pokriće rashoda za decentralizirane funkcije osnovnog i srednjeg školstva, socijalne skrbi, zdravstva i vatrogastva* (članak 10. Zakona), te također osigurava i pomoć izravnanja za decentralizirane funkcije kako bi se dosegnuo minimalni financijski standard za pojedinu decentraliziranu funkciju. *Pomoć izravnanja predstavljaju prijenos sredstava iz državnog proračuna jedinicama lokalne i područne (regionalne) samouprave za financiranje decentraliziranih funkcija kada prihodi ostvareni iz dodatnog udjela poreza na dohodak nisu dovoljni za financiranje minimalnih financijskih standarda* (Uredba Vlade Republike Hrvatske[26]). Sredstva se državnog proračuna koriste u situacijama u kojima lokalna jedinica ne prikupi dovoljno sredstava temeljem dodatnog udjela u porezu na dohodak da bi financirala preuzete funkcije, odnosno financirala minimalni financijski standard školstva, zdravstva, vatrogastva i ostalih zakonom propisanih funkcija.

Instrumentima javnih financija, dakle, sve se više nastoje ostvariti i nefiskalni ciljevi koji se mogu grupirati u tri skupine: alokacijski ciljevi (aktivnost države kojom se osigurava raspodjela i korištenje faktora proizvodnje), redistribucijski ciljevi (korigiranje raspodjele dohotka i imovine do koje je došlo djelovanjem tržišnog mehanizma) i stabilizacijski ciljevi (očuvanje pune zaposlenosti odnosno smanjenje nezaposlenosti i očuvanje postojeće razine cijena) (Jelčić 1990: 584). Lokalne jedinice koje financijski i razvojno zaostaju imaju pravo na financijska sredstva iz državnog proračuna. Naime, jedinice *čiji je kapacitet ostvarenih poreznih prihoda manji od referentne vrijednosti kapaciteta ostvarenih poreznih prihoda, ostvaruju pravo na sredstva fiskalnog izravnanja* (Zakon o financiranju jedinica lokalne i područne (regionalne) samouprave, čl. 8.). Važno je istaknuti da *fiskalno izravnanje obavlja redistribucijsku funkciju preusmjeravanja sredstava iz bogatijih u siromašnije jedinice* (Hohnjec i suradnici 2017: 6). Trenutni model fiskalnog izravnanja temelji se na nekoliko varijablā: maksimalnom poreznom prihodu (tzv. kapacitet), prosjeku ostvarenih poreznih prihoda (referentna vrijednost) i sredstvima fiskalnog izravnanja. Kapacitetom se smatra zbroj petogodišnjeg prosjeka ostvarenih prihoda od poreza na dohodak i prihoda od prireza koji bi bio ostvaren uvođenjem najviše propisane stope za pojedinu općinu ili grad (bez Grada Zagreba). Dakle, kapacitet predstavlja varijablu koja se sastoji od stvarnih vrijednosti poreza i prireza te matematički iskalkuliranog ostatka neuvedenog prireza (za gradove koji nisu uveli

[26] Uredba o načinu izračuna iznosa pomoći izravnanja za decentralizirane funkcije jedinica lokalne i područne (regionalne) samouprave za 2020. godinu

maksimalnu stopu prireza). Referentna vrijednost za gradove prosjek je kapaciteta svih 127 gradova, dok se referentna vrijednost za općine računa na način da se prosječni zbroj uveća za dodatnih 50 %. Ovakvim se izračunom ide u korist općinama jer se najveći dio njih u tom trenutku nalazio ispod referentnih vrijednosti i na taj način općine postaju korisnikom sredstava fiskalnog izravnanja.

Sredstva fiskalnog izravnanja u punom iznosu za jednu općinu/grad izračunavaju se i na dnevnoj razini i isplaćuju temeljem razlike nastale između referentne vrijednosti za sve općine/gradove i kapaciteta svih općina/gradova pomnoženu s ukupnim brojem stanovnika lokalne jedinice. Za 2019. godinu, 348 od ukupno 428 općina dobilo je sredstva fiskalnog izravnanja, zatim 92 grada od ukupno 128 gradova te 15 županija od ukupno njih 20. Dakle, ukupno 455 lokalnih jedinica vlasti koristilo je sredstva fiskalnog izravnanja (17 % svih prikupljenih sredstava poreza na dohodak). Tijekom 2020. godine došlo je do blagog smanjenja jedinica koje su koristile sredstva fiskalnog izravnanja, ali i dalje to iznosi visokih 78 % ukupnog broja jedinica (tablica 6).

Tablica 6. Raspodjela sredstava fiskalnog izravnanja u periodu od 2018. do 2020. godine

Fiskalno izravnanje	2018.		2019.		2020.	
Općine	347	81,1 %	348	81,3 %	346	80,8 %
Gradovi	92	71,9 %	92	71,9 %	88	68,8 %
Županije	15	75,0 %	15	75,0 %	15	75,0 %
Ukupno	**454**	**78,8 %**	**455**	**79,0 %**	**449**	**78,0 %**

Izvor: Izračun autora temeljen na podatcima Ministarstva financija Republike Hrvatske[27]

U sklopu reforme poreznog sustava Republike Hrvatske, krajem 2016. godine, donesen je novi zakon kojim se *uređuje sustav utvrđivanja i naplate lokalnih poreza kao izvora financiranja jedinica lokalne i područne (regionalne) samouprave* (Zakon o lokalnim porezima[28]). Važno je napomenuti da su lokalni porezi, porezi koji pripadaju jedinicama lokalne samouprave, ali i županijama. U tablici br. 7 prikazan je povijesni pregled kretanja lokalnih poreza, odnosno prikaz poreznih prihoda koji su bili, ili su još uvijek, na raspolaganju lokalnim jedinicama (općinama i gradovima).

[27] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/fiskalno-izravnanje/202 (pristupljeno: 11. studenoga 2020.).
[28] Zakon o lokalnim porezima (Narodne novine 115/2016, 101/2017).

Trenutno gradovi, sukladno zakonu, mogu uvesti sljedeće poreze:

1. *prirez porezu na dohodak*
2. *porez na potrošnju*
3. *porez na kuće za odmor*
4. *porez na korištenje javnih površina* (Zakon o lokalnim porezima, čl. 20.).

Sva četiri navedena poreza na raspolaganju su gradovima od 1994. godine glede planiranja prihoda i proračuna. S vremenom su dva porezna oblika ukinuta i ne predstavljaju više prihode proračuna gradova, a to su: porez na reklame (ukinut je 2001. godine) i porezu na tvrtku ili naziv (ukinut je 2017. godine).

Tablica 7. Povijesni pregled najvažnijih normativnih promjena lokalnih poreza

Vrsta poreza	1994.	2001.	2007.[29]	2018.
Prirez porezu na dohodak	+	+	+	+
Porez na potrošnju	+	+	+	+
Porez na kuće za odmor	+	+	+	+
Porez na reklame	+	-	-	-
Porez na korištenje javnih površina	+	+	+	+
Porez na tvrtku ili naziv	+	+	+	-
Poreza na neobrađeno obradivo poljoprivredno zemljište	-	+	-	-
Poreza na nekorištene poduzetničke nekretnine	-	+	-	-
Porez na neizgrađeno građevinsko zemljište	-	+	-	-

Izvor: Prikaz autora na temelju Zakona o financiranju jedinica lokalne i područne (regionalne) samouprave i Zakona o lokalnim porezima.[30]

Kao što je već navedeno, dio je prikazanih poreznih prihoda ukinut odlukom Ustavnog suda, jer se po mišljenju suda ne smije oporezivati neaktivnost.

2.2.2.1. Prirez

Prirez predstavlja dodatni oblik fiskalnog opterećenja brutoplaća i to na način da se prvo izračuna porez na dohodak temeljem zakonskih poreznih stopa i porezne osnovice, a zatim se na tako izračunatu poreznu obvezu izračunava prirez koji dodatno umanjuje dohodak.

[29] Zakon o financiranju jedinica lokalne i područne (regionalne) samouprave (1993) Objava: Narodne novine br. 26/07 – izmjene zbog odluke Ustavnog suda (12. ožujka 2007.).
[30] Narodne novine br. 117/1993, 92/1994, 69/1997, 33/2000, 73/2000, 127/2000, 59/2001, 107/2001, 117/2001, 150/2002, 147/2003, 132/2006, 26/2007, 73/2008, 25/2012, 147/2014, 100/2015, 115/2016, 127/2017 i Narodne novine br. 115/2016, 101/2017.

Predstavničko tijelo općine, odnosno grada može *obveznicima poreza na dohodak sa svoga područja propisati plaćanje prireza porezu na dohodak* prema članku 21. na sljedeći način:

1. *općina po stopi do 10 %*
2. *grad s manje od 30.000 stanovnika po stopi do 12 %*
3. *grad s više od 30.000 stanovnika po stopi do 15 %*
4. *Grad Zagreb po stopi do 18 %* (Zakon o lokalnim porezima).

Prirez porezu na dohodak, po odredbama ovoga članka, plaća se po stopi koju utvrdi općina ili grad i pripada općini ili gradu na području kojih je prebivalište ili uobičajeno boravište obveznika prireza (Zakon o lokalnim porezima). Prema podatcima Porezne uprave[31], u tablici br. 8 nalazi se pregled stopa prireza u velikim gradovima i gradovima sjedištima županija u Republici Hrvatskoj. Zagreb primjenjuje maksimalnu zakonsku stopu prireza od 18 %, Rijeka i Split imaju prirez u visini od 15 %, što također predstavlja maksimalnu stopu za grad iznad 30 000 stanovnika, dok Osijek i Vinkovci imaju prirez porezu na dohodak u visini od 13 %. Tablicom su obuhvaćeni i gradovi kao što je Samobor, Koprivnica, Vukovar i Krapina koji trenutno nemaju uveden prirez porezu na dohodak.

Tablica 8. Stope prireza u velikim gradovima (u postotcima)

Veliki grad	Stopa prireza	Veliki grad	Stopa prireza
ZAGREB	18 %	VARAŽDIN	10 %
RIJEKA	15 %	ŠIBENIK	10 %
SPLIT	15 %	DUBROVNIK	10 %
OSIJEK	13 %	ČAKOVEC	10 %
VINKOVCI	13 %	POŽEGA	10 %
ZADAR	12 %	VIROVITICA	10 %
VELIKA GORICA	12 %	PAZIN	9 %
SLAVONSKI BROD	12 %	BJELOVAR	6 %
PULA	12 %	SAMOBOR	0 %
KARLOVAC	12 %	KOPRIVNICA	0 %
KAŠTELA	12 %	VUKOVAR	0 %
GOSPIĆ	10 %	KRAPINA	0 %
SISAK	10 %		

Izvor: Prikaz autora na temelju podatka Ministarstva financija Republike Hrvatske, Porezne uprave[32]

[31] Porezna uprava na svojim internetskim stranicama nudi pregled svih lokalnih jedinica koje su uvele prirez porezu na dohodak: http://www.porezna-uprava.hr/HR_porezni_sustav/Stranice/prirez_porezu_na_dohodak.aspx (pristupljeno: 16. ožujka 2020.).

[32] https://www.porezna-uprava.hr/HR_porezni_sustav/Stranice/prirez_porezu_na_dohodak.aspx (pristupljeno: 16. ožujka 2020.).

2.2.2.2. Porez na potrošnju

Porez na potrošnju plaća se na potrošnju alkoholnih pića (vinjak, rakiju i žestoka pića), prirodnih vina, specijalnih vina, piva i bezalkoholnih pića u ugostiteljskim objektima (članak 22. Zakona o lokalnim porezima). Gradovi i općine svojim odlukama propisuju visinu stope poreza na potrošnju, koja *ne može biti veća od 3 % od osnovice na koju se plaća porez na potrošnju* (članak 24. istog zakona). Porez na potrošnju ne pripada u skupinu najznačajnijih proračunskih prihoda gradova jer je primjerice grad Osijek s te osnove u 2019. godini ostvario 3,3 milijuna kuna, a što predstavlja svega 0,7 % ukupnih proračunskih prihoda.

2.2.2.3. Porez na kuće za odmor

Vlasnici nekretnina u Republici Hrvatskoj plaćaju svojevrstan porez na nekretnine jedino ukoliko su njihove nekretnine namijenjene za odmor. Naime, propisano je da *porez na kuće za odmor plaćaju pravne i fizičke osobe koje su vlasnici kuća za odmor* (Zakon o lokalnim porezima, čl. 25.). Općine i gradovi koji se nalaze blizu mora ostvaruju značajne prihode s ove osnove. Također, značajan je to prihod lokalnih jedinica u unutrašnjosti Istre, u blizini nacionalnih parkova i parkova prirode, ali i lokalnih jedinica koja su u blizini velikih gradova, a predstavljaju tradicionalna vikend naselja građana. *Plaća se od 5,00 do 15,00 kuna po jednom četvornom metru korisne površine kuće za odmor, a visinu poreza propisuje svojom odlukom predstavničko tijelo lokalne jedinice* (Zakon o lokalnim porezima, čl. 26.).

2.2.2.4. Porez na korištenje javnih površina

Lokalne jedinice mogu naplaćivati zakup svojih javnih površina i uz to ostvariti dodatni izvor prihoda putem oporezivanja korištenja tih istih javnih površina. Navedeni porez *plaćaju pravne i fizičke osobe koje koriste javne površine, a plaća se u visini, na način i pod uvjetima koje odrede općina ili grad* (Zakon o lokalnim porezima, čl. 29.). Također, oni određuju svojom odlukom i što se smatra javnom površinom. Tako prema Odluci o komunalnom redu[33] Grada Osijeka postoji osnovna podjela na četiri vrste javnih površina:

1. *Javne zelene površine: gradski parkovi, park šume, drvoredi, živice, cvjetnjaci, travnjaci, skupine ili pojedinačna stabla, dječja igrališta s pripadajućom opremom, drugi oblici vrtnog i parkovnog oblikovanja koji nisu proglašeni zaštićenim dijelovima prirode, javni sportski i rekreacijski prostori, zelene*

[33] Odluka o komunalnom redu (Službeni glasnik Grada Osijeka br. 10/19)

površine uz ceste i ulice, ako nisu sastavni dio nerazvrstane ili druge ceste odnosno ulice i sl.,

2. *Javne prometne površine na kojima nije dopušten promet motornim vozilima: trgovi, pločnici, javni prolazi, javne stube, prečaci, šetališta, uređene plaže, biciklističke i pješačke staze, pothodnici, podvožnjaci, nadvožnjaci, mostovi i tuneli, ako nisu sastavni dio nerazvrstane ili druge ceste,*
3. *Javne prometne površine: nerazvrstane ceste te dijelovi javnih cesta koje prolaze kroz naselje, kad se ti dijelovi cesta ne održavaju kao javne ceste prema posebnom zakonu, javna parkirališta, javne garaže, površine određene za zaustavljanje vozila i siguran ulazak i izlazak putnika (stajališta komunalnog linijskog prijevoza putnika), kolodvori i slične površine koje se koriste za promet po bilo kojoj osnovi,*
4. *Ostale javne površine: površine javnih tržnica na malo, površine na kojima se prodaje roba na štandovima i klupama izvan tržnica na malo i slični prostori, otvoreni kanali za oborinsku odvodnju i sl.*

Nadalje, odlukom koja je bila na snazi do kraja 2020. godine Grad Osijek propisivao je da se *na korištenje javnih površina obračunava i plaća porez po stopi od 10 % na ugovoreni iznos naknade koja se plaća za korištenje javnih površina* (Odluka o gradskim porezima, čl. 17.). Dodatno - *rješenje o utvrđivanju poreza na korištenje javnih površina donosio je Grad Osijek na temelju rješenja ili ugovora o zakupu javne površine* (Odluka o gradskim porezima, čl. 18.). Postoje gradovi i općine koji ovaj porez utvrđuju u apsolutom iznosu te onda obično visina ovisi o zoni u kojoj se nalazi javna površina. Visokofrekventne lokacije, obično u središtu nekog grada ili stare gradske jezgre, čine zonu u kojoj su porezi najviši, a udaljenije lokacije su u zonama u kojima je i porezno opterećenje niže ili ga nema. Uz to, prema Krmpotiću (2015), javne površine najčešće se koriste za postavljanje:

1. Kioska ili drugog montažnog objekta.
2. Ugostiteljskih terasa.
3. Privremenih objekata (pokretne naprave, uslužne naprave, štandovi i sl.).
4. Reklamnih predmeta (panoi, tende, totemi, ograde i sl.).
5. Ostale događaje (organiziranje zabava i manifestacija).

Grad Pula jedan je od gradova koji obračunava porez na korištenje javnih površina prema apsolutnim iznosima, a temeljem svoje Odluke o lokalnim porezima[34]. U navedenoj su odluci detaljno razrađene odredbe vezane za postavljanje ugostiteljskih terasa, a najveći utjecaj na konačni iznos poreza ima kombinacija zone i trajanja zakupa (tablica br. 9).

Tablica 9. Porez na korištenje javnih površina za postavljanje ugostiteljskih terasa

Vrsta ugostiteljske terase s obzirom na razdoblje postavljanja	Mjesečni iznos poreza u kunama po m²			
	Zona visoke frekventnosti unutar I. zone	I. zona – izvan zone visoke frekventnosti	II. zona	III. zona
Stalna (1. 1. - 31. 12.)	100,00	80,00	60,00	40,00
Sezonska + dva/četiri mjeseca (1. 5. - 31. 10.) (1. 4. - 30. 11.)	110,00	90,00	70,00	50,00
Sezonska (1. 6. - 30. 9.)	140,00	120,00	100,00	80,00

Izvor: Prikaz autora na temelju podataka Grada Pule (Odluka o lokalnim porezima)

2.2.2.5. Ostali porezni prihodi

Važno je još istaknuti kako mnogi autori, a među njima i Marković i Matić (2006), smatraju da bi *država morala dodatno povećati autonomiju lokalnih jedinica za uvođenje novih prihoda, osobito poreza te poticati lokalne jedinice u većoj realizaciji svojih nefiskalnih prihoda*. Porez na promet nekretnina dodatni je porezni prihod koji u potpunosti pripada *jedinicama lokalne samouprave na čijem se području nekretnina nalazi*. *Porez na promet nekretnina plaća se po stopi od 3 %* (Zakon o porezu na promet nekretnina, čl. 12.)[35]. Grad Osijek u 2018. ostvario je 29,3 milijuna kuna s osnova, tzv. *povremenih poreza na imovinu*, a na razini Republike Hrvatske svi su gradovi imali prihod u ukupnom iznosu od 933,5 milijuna kuna.

2.2.3. Europska povelja o lokalnoj samoupravi

Vijeća Europe najstarija je europska organizacija koja obuhvaća 47 država članica, a glavni joj je cilj jačanje suradnje i jedinstva na europskom kontinentu, promicanje ljudskih prava i temeljnih sloboda te demokracije i vladavine prava (Ministarstvo vanjskih i europskih poslova)[36].

[34] Odluka o lokalnim porezima Grada Pula - Pola (Narodne novine br. 60/2017, 126/2017).
[35] Zakon o porezu na promet nekretnina (Narodne novine 115/2016, 106/2018).
[36] http://www.mvep.hr/hr/vanjska-politika/multilateralni-odnosi0/multi-org-inicijative/vijece-europe/opcenito-o-vijecu-europe/ (pristupljeno: 19. listopada 2020.).

Shodno tome u preambuli Europske povelje, koju su potpisale strane članice Vijeća 15. listopada 1985. godine, stoji *da su lokalne jedinice jedan od glavnih temelja demokratskih režima te da je pravo građana na sudjelovanje u upravljanju javnim poslovima jedno od osnovnih demokratskih načela koje dijele sve članice Vijeća* (Europske povelje o lokalnoj samoupravi). Također, postojanje lokalnih jedinica sa stvarnim ovlastima može osigurati administraciju koja je i učinkovita i *blizu* građanima. Ova je povelja bila od iznimnog značaja s obzirom na to da se radi o vremenu pred sam raspad komunistički vođenih država u kojima je jačala težnja za demokratizacijom. Tim je putem išla i Republika Hrvatska koja je u studenom 1996. godine postala punopravnom članicom Vijeća Europe, Europsku povelju o lokalnoj samoupravi potvrdila je Zakonom o potvrđivanju Europske povelje o lokalnoj samoupravi te je početkom 1998. godine Povelja djelomično i stupila na snagu.

Povelja je u potpunosti prihvaćena tek u svibnju 2008. godine, a do danas su ju ratificirale i gotovo sve članice Vijeća.

Krmpotić (2015), napominje kako je poveljom utvrđena koncepcija i djelokrug lokalne samouprave, zatim prilagođavanje upravnog ustroja i, možda još važnije, sredstava zadaćama koje se pred lokalne jedinice stavljaju te uvjeti obnašanja dužnosti na lokalnoj razini. U dijelu vezanom za financijske izvore lokalnih jedinica, između ostalog se navodi da prihodi moraju biti razmjerni ovlastima predviđenima ustavom i zakonima te je nužno provesti određene postupke ili mjere financijskog ujednačavanja zbog zaštite financijski slabijih lokalnih jedinica.

3. Proračun i dug gradova

Proračun[37] je temeljni financijski i pravni akt te ključan instrument fiskalne politike lokalnih jedinica, a njime *se procjenjuju prihodi i primitci te utvrđuju rashodi i izdatci* (Zakon o proračunu). *Sredstva proračuna koriste se za financiranje poslova, funkcija i programa tijela lokalnih jedinica i korisnika proračuna* (Bajo, Jurlina Alibegović 2008: 216). Isto je tako proračun i planski dokument koji ima svoju definiranu strukturu te *se sastoji od općeg i posebnog dijela, a na razini jedinica lokalne i područne (regionalne) samouprave i od plana razvojnih programa* (Zakon o proračunu, čl. 16.). *Proračun donosi predstavničko tijelo prije početka godine na koju se odnosi* (Zakon o proračunu). Donosi se svake godine za jednu (kalendarsku) godinu, a uz proračun predstavničko tijelo usvaja i proračunske projekcije za buduće dvogodišnje razdoblje. Prema Krmpotiću (2015), proračun je izuzetno važan politički dokument jer se putem proračuna provodi program temeljem kojeg je određena politička opcija i pridobila glasove birača te preuzela upravljanje izvršnom vlasti[38]. Tijekom godine proračun se mijenja i iz planskog dokumenta postaje dokument pomoću kojeg se upravlja izvršavanjem prihoda i rashoda, ali i pomoću kojeg predstavničko tijelo i javnost imaju uvid u realizaciju proračunskih stavki. Uravnoteženost proračuna nužan je preduvjet za pravodobno pomirenje svih preuzetih obveza. Rogić, Lugarić (2012: 106) ističe - *da proračunski dokumenti, osim svega navedenog, trebaju služiti i povećanju odgovornosti i transparentnosti ukupnog financijskog sustava*.

3.1. Proračun

Proračun lokalnih jedinica vlasti definira se kao *glavni instrument fiskalne politike lokalnih jedinica čijim se prihodima osigurava financiranje planiranih rashoda u tijeku jedne ili više godina* (Bajo, Jurlina Alibegović 2008: 216). Zakon detaljno *uređuje planiranje, izradu, donošenje i izvršavanje proračuna, upravljanje imovinom i dugovima, upravljanje javnim dugom, zaduživanje i jamstvo države te jedinica lokalne i područne (regionalne) samouprave,*

[37] Državni proračun donosi Sabor Republike Hrvatske na prijedlog Vlade Republike Hrvatske. Izvršenje državnog proračuna za 2019. godinu iznosilo je 139,9 milijardi kuna (rashodovno), dok planirani proračun za 2020. godinu donesen 14. studenog 2019. godine iznosi 147,3 milijardi kuna (rashodovno). https://mfin.gov.hr/proracun-86/86 (pristupljeno: 17. listopada 2020.).

[38] Ponekad se dogodi situacija u kojoj jedna politička opcija upravlja izvršnom vlasti, a druga ima većinu u predstavničkom tijelu, ali te situacije u pravilu brzo završe krizom vlasti i prijevremenim izborima za predstavničko tijelo, a ponekad i izvršnu vlast.

proračunske odnose u javnom sektoru, računovodstvo, proračunski nadzor i druga pitanja vezana uz upravljanje javnim financijama (Zakon o proračunu, čl. 1.).

Odredbe Zakona o proračunu odnose se na državni proračun i proračune jedinica lokalne i područne (regionalne) samouprave te proračunske korisnike državnog proračuna i proračunske korisnike proračuna jedinica lokalne i područne (regionalne) samouprave (Zakon o proračunu). Dodatno se navodi kako *su proračunski korisnici državna tijela, ustanove, vijeća manjinske samouprave, proračunski fondovi i mjesna samouprava čiji se rashodi za zaposlene i/ili materijalni rashodi osiguravaju u proračunu* (Zakon o proračunu, čl. 3.). Prema Krmpotiću (2015), *Grad Osijek na ovaj način direktno financira rad ustanova u kulturi (Hrvatsko narodno kazalište u Osijeku, Dječje kazalište Branka Mihaljevića, Gradske galerije i Kulturni centar) i obrazovanju (Dječji vrtići Osijek, Centar za odgoj i obrazovanje Ivan Štark, Prosvjetno-kulturni centar Mađara u Republici Hrvatskoj), rad Javne profesionalne vatrogasne postrojbe Grada Osijeka te rad svih osnovnih škola s područja grada*.

Važno je istaknuti da *pojedine odredbe navedenog zakona uređuju proračunske odnose i pravila koja se primjenjuju na izvanproračunske korisnike, odnosno izvanproračunske fondove, trgovačka društva i druge pravne osobe u kojima država, odnosno jedinica lokalne i područne (regionalne) samouprave ima odlučujući utjecaj na upravljanje i to na izradu financijskih planova, upravljanje novčanim sredstvima, zaduživanje i davanje jamstava, računovodstvo, izradu i podnošenje izvještaja i provedbu proračunskog nadzora. Izvanproračunski se korisnici, s obzirom na izvore financiranja, uključuju u opći proračun, odnosno oni se sukladno pravilima statističke metodologije Europske unije razvrstavaju u sektor opće države* (Zakon o proračunu).

3.1.1. Struktura proračuna i proračunske klasifikacije

Lokalne jedinice vode svoje poslovne knjige pridržavajući se važećih zakona i ostalih propisa. *Poslovne knjige proračuna i proračunskih korisnika su: dnevnik, glavna knjiga i pomoćne knjige* (Pravilnik o proračunskom računovodstvu i računskom planu, čl. 6.). *Dnevnik je knjiga u koju se unose poslovne promjene slijedom vremenskog nastanka*, dok glavna knjiga predstavlja *sustavnu knjigovodstvenu evidenciju poslovnih promjena i transakcija nastalih na imovini, obvezama, vlastitim izvorima te prihodima i rashodima* (isti Pravilnik). *Pomoćne knjige predstavljaju analitičke knjigovodstvene evidencije stavki koje su u glavnoj knjizi iskazane sintetički te druge pomoćne evidencije za potrebe nadzora i praćenja poslovanja* (isti Pravilnik).

Proračun i proračunski korisnici, temeljem članka 7. istog pravilnika, imaju obvezu voditi analitička knjigovodstva, a tu ubrajamo evidencije:

1. *dugotrajne nefinancijske imovine*
2. *kratkotrajne nefinancijske imovine (zaliha materijala, proizvoda i robe)*
3. *financijske imovine i obveza:*
    a. *potraživanja i obveza (po subjektima, računima, pojedinačnim iznosima, rokovima dospjelosti, zateznim kamatama i dr.)*
    b. *obveze po ugovorima koji zahtijevaju plaćanje u sljedećim godinama,*
    c. *primljenih i izdanih vrijednosnih papira i drugih financijskih instrumenata (po vrstama, subjektima, pojedinačnim vrijednostima, dospjelosti, stanjima)*
    d. *potraživanja i obveza po osnovi primljenih kredita i zajmova te danih zajmova (po vrstama, subjektima, pojedinačnim vrijednostima, dospjelosti, obračunatim kamatama)* (Pravilnik o proračunskom računovodstvu i računskom planu).

Kvalitetnim i ažurnim vođenjem osnovnih evidencija, prije svih evidencija o potraživanjima i obvezama, omogućava se i kvalitetnije planiranje uravnoteženih prihoda i rashoda te pravodobno ispunjavanje svih dospjelih obveza.

Pravilnik definira sadržaj računskoga plana koji se sastoji od 10 razreda:

1. *Nefinancijska imovina (razred 0)*
2. *Financijska imovina (razred 1)*
3. *Obveze (razred 2)*
4. *Rashodi poslovanja (razred 3)*
5. *Rashodi za nabavu nefinancijske imovine (razred 4)*
6. *Izdatci za financijsku imovinu i otplate zajmova (razred 5)*
7. *Prihodi poslovanja (razred 6)*
8. *Prihodi od prodaje nefinancijske imovine (razred 7)*
9. *Primitci od financijske imovine i zaduživanja (razred 8)*
10. *Vlastiti izvori (razred 9)* (Pravilnik o proračunskom računovodstvu i računskom planu, čl. 22.).

Imovinu lokalnih jedinica moguće je dakle podijeliti *na nefinancijsku i financijsku imovinu*. Nefinancijska imovina sastoji se od ne proizvedene i proizvedene dugotrajne imovine, dok financijsku imovinu čine novac i različite vrste potraživanja. Važno je istaknuti i da se *ne proizvedena dugotrajna imovina sastoji od materijalne i nematerijalne imovine* (isti Pravilnik, čl. 24.). *Materijalna imovina obuhvaća prirodna bogatstva kao što su: zemljišta, rudna bogatstva (nafta, plin i dr.), vodna bogatstva (vode), nacionalne parkove i parkove prirode i sl., dok nematerijalna imovina obuhvaća: patente, licence, koncesije te uz ostala slična prava i goodwill*[39] (isti Pravilnik, čl. 24.). *Proizvedena dugotrajna imovina sastoji se od: građevinskih objekata, postrojenja i opreme, vojne opreme, prijevoznih sredstava, knjiga, umjetničkih djela i ostalih izložbenih vrijednosti, višegodišnjih nasada i osnovnog stada i nematerijalne proizvedene imovine (istraživanja rudnih bogatstava, ulaganja u računalne programe, umjetničkih, literarnih i znanstvenih djela i slično)* (isti Pravilnik, čl. 25.). Zbog iznimne kompleksnosti, ali i važnosti, osnovna je podjela imovine prikazana slikom br. 4.

Slika 4. Bilančna podjela imovine lokalnih jedinica

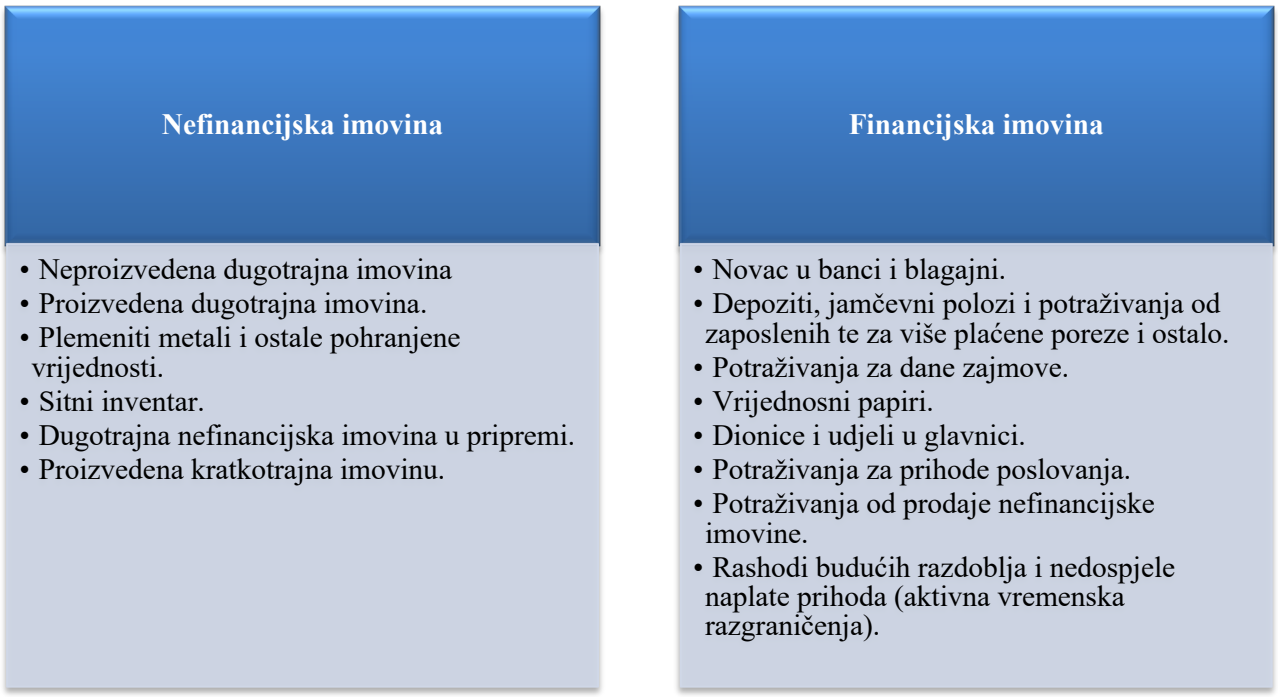

Izvor: Krmpotić (2015) na temelju podataka iz Pravilnika o proračunskom računovodstvu i računskom planu

[39] *Goodwill je više plaćeni iznos od iznosa utvrđenog kao razlika između imovine i obveza kupljenoga trgovačkog društva* (članak 24. Pravilnika).

Pasivnu stranu bilance lokalnih jedinica čine obveze za:

1. *rashode poslovanja*
2. *nabavu nefinancijske imovine*
3. *vrijednosne papire*
4. *kredite i zajmove*
5. *odgođeno plaćanje rashoda i prihoda budućih razdoblja (pasivna vremenska razgraničenja)* (isti Pravilnik čl. 40.).

Obveze za rashode poslovanja sastoje se od *obveze za: zaposlene, materijalne rashode, financijske rashode (primjerice obveze za kamate po primljenim kreditima i zajmovima te obveze za kamate po izdanim vrijednosnim papirima), subvencije*[40]*, naknade građanima i kućanstvima, kazne, naknade šteta i kapitalne pomoći*[41] *te ostale tekuće obveze* (isti Pravilnik, čl. 41.). *Obveze za nabavu nefinancijske imovine sadrže obveze za nabavu: ne proizvedene dugotrajne imovine, proizvedene dugotrajne imovine, plemenitih metala i ostalih pohranjenih vrijednosti, zaliha te obveze za dodatna ulaganja na nefinancijskoj imovini* (isti Pravilnik, čl. 42.).

Obveze za vrijednosne papire obuhvaćaju obveze za vrijednosne papire klasificirane prema vrstama financijskih instrumenata, a obveze za kredite i zajmove obuhvaćaju obveze koje proračuni i proračunski korisnici imaju za primljene kredite i zajmove, faktoring te financijski leasing (isti Pravilnik, čl.44.).

Pokazatelji održivosti aktivnosti proračuna izračunavaju se temeljem razlike između imovine i obveza što čini financijsku neto vrijednost, a razlika između ukupne imovine i obveza neto vrijednost. *Opći dio proračuna čini Račun prihoda i rashoda te Račun financiranja* (Zakon o proračunu). Višak prihoda iz prethodnih godina koji predstavlja dodatna raspoloživa sredstva ili manjak prihoda koji je potrebno pokriti u budućem razdoblju, te rezerviranja također se nalaze u općem dijelu proračuna.

[40] Sukladno članku 3. Zakona *subvencije su tekući prijenosi sredstava koji se daju proizvođačima za poticanje proizvodnje određenih proizvoda i pružanja usluga, a mogu se utvrđivati na temelju razine proizvodnje i/ili količine proizvedenih, prodanih ili uvezenih dobara i usluga* (Zakon o proračunu, Narodne novine 87/2008, 109/2007, 136/2012, 15/2015).

[41] U *kapitalne pomoći klasificiraju se prijenosi nefinancijske imovine ili sredstava za financiranje troškova nefinancijske imovine trgovačkim društvima, za pokriće ukupnog gubitka koji se stvarao tijekom dvije ili više godina i za otpisivanje duga na temelju dogovora (ugovora) s dužnikom* (Pravilnik o proračunskom računovodstvu i računskom planu, čl. 54.).

U dijelu prihoda poslovanja detaljno su razrađeni porezni prihodi, prihodi od pomoći subjekata unutar općeg proračuna, prihodi od imovine, raznih kazni, pristojbi i naknada. Lokalnim vlastima važni su i prihodi od prodaje nefinancijske (ne proizvedene dugotrajne materijalne) imovine, odnosno prirodnih bogatstava (građevinska zemljišta) i građevinskih objekata (npr. poslovnih prostora ili stanova). Prihodi poslovanja čine najznačajniji izvori prihoda lokalnih jedinica i na njih se, u pravilu, odnosi preko 90 % svih prihoda (uključujući i primitke), a najznačajniji u strukturi prihoda poslovanja su, dakako, prihodi od prikupljenih poreza koji obično iznose oko 50 % ukupnih proračunskih prihoda.

Kod rashoda poslovanja, prema redoslijedu u kontnom planu, posloženi su rashodi za zaposlene, materijalni rashodi, financijski rashodi (kamate na izdane vrijednosne papire ili primljene kredite), subvencije trgovačkim društvima, donacije i kapitalne pomoći, te naknade. Tu su još i rashodi za nabavu ne proizvedene i proizvedene dugotrajne imovine, te dodatna ulaganja na nefinancijskoj imovini. Ukupno gledajući, rashodi poslovanja obično sudjeluju s udjelom od 80 % ukupnih rashoda (uključujući i izdatke). U kvantitativnom su iznosu najveći materijalni rashodi i dane pomoći (svaka stavka sa otprilike 25 % ukupnih rashoda) te rashodi za zaposlene u lokalnim jedinicama. Također, značajna su trošenja unutar kategorije rashoda vezana za nabavu nefinancijske imovine, koji iznose 15 do 20 % svih rashoda u odnosu na ukupne rashode. *Račun financiranja ili zaduživanja sastoji se od primitaka od financijske imovine i zaduživanja (npr. primljeni krediti i zajmovi kreditnih i ostalih financijskih institucija) te izdataka za financijsku imovinu i otplate zajmova* (Zakon o proračunu).

Osim općeg dijela proračuna, proračun ima i posebni dio. *Posebni se dio proračuna sastoji od plana rashoda i izdataka proračunskih korisnika*[42] (Zakon o proračunu). Radi se o institucijama *kojima su osnivači lokalne jedinice, kojima je izvor prihoda lokalni proračun u iznosu 50 % ili više i koje su navedene u registru*[43] *korisnika proračuna* (Bajo, Jurlina Alibegović 2008: 216). Rashodi i izdatci proračunskih korisnika iskazani su po vrstama te su raspoređeni u programe koji se sastoje od aktivnosti i projekata.

[42] *Proračunski korisnici su državna tijela, ustanove, vijeća manjinske samouprave, proračunski fondovi i mjesna samouprava čiji se rashodi za zaposlene i/ili materijalni rashodi osiguravaju u proračunu* (Zakon o proračunu, čl. 3.).

[43] *Registar korisnika proračuna je popis proračunskih i izvanproračunskih korisnika državnog proračuna i proračunskih i izvanproračunskih korisnika proračuna jedinica lokalne i područne (regionalne) samouprave. Ustrojava ga i vodi Ministarstvo financija* (Pravilnik o utvrđivanju proračunskih i izvanproračunskih korisnika državnog proračuna i proračunskih i izvanproračunskih korisnika proračuna jedinica lokalne i područne (regionalne) samouprave te o načinu vođenja Registra proračunskih i izvanproračunskih korisnika, čl. 2. i 3.).

Naime, proračun je organizacijski podijeljen u razdjele, a razdjeli se sastoje od jedne ili više glava, prema članku 6. Pravilnika o proračunskim klasifikacijama, u kojima se mogu nalaziti proračunski korisnici. Plan razvojnih programa posljednji je obvezni sastavni dio proračuna. To je dokument *jedinice lokalne i područne (regionalne) samouprave sastavljen za trogodišnje razdoblje, koji sadrži ciljeve i prioritete razvoja jedinice lokalne i područne (regionalne) samouprave povezane s programskom i organizacijskom klasifikacijom proračuna* (Zakon o proračunu). Bitno je napomenuti da taj dokument, osim navedenog, sadrži i mjere, pokazatelje rezultata (primjerice, radi li se o kilometrima nove biciklističke staze ili o broju novih energetski efikasnih rasvjetnih tijela), polazne i ciljane vrijednosti te odgovornost za provedbu mjera (Krmpotić 2015).

Osim proračuna, veliku ulogu u financijskom funkcioniranju sustava na lokalnoj razini imaju financijski planovi korisnika. *Financijski plan proračunskih korisnika čine prihodi i primitci te rashodi i izdatci raspoređeni u programe koji se sastoje od aktivnosti i projekata* (Zakon o proračunu, čl. 17.).

Financijski plan izvanproračunskih korisnika[44] *sastoji se od općeg dijela kojeg čine račun prihoda i rashoda i račun financiranja i posebnog dijela u kojem su iskazani prihodi i primitci te rashodi i izdatci raspoređeni u programe, a sastoje se od aktivnosti i projekata* (Zakon o proračunu, čl. 17.).

Čelni ljudi lokalnih jedinica dužni su, kod pripreme, donošenja i izvršavanja proračuna pridržavati se nekoliko osnovnih načela koja su definirana člankom 4. Zakona o proračunu. Načelo jedinstva i točnosti proračuna kaže da se prihodi i primitci te rashodi i izdatci iskazuju po *brutonačelu*[45] i da se *sredstva proračuna koriste u visini utvrđenoj proračunom* (Zakon o proračunu, čl. 5.). Kao što je već ranije spomenuto, proračunski se prihodi i rashodi planiraju za jednu kalendarsku godinu[46] (Zakon o proračunu, čl. 6.), a o tome govori i načelo jedne godine. *Racionalnost u trošenju raspoloživih proračunskih sredstava i pravodobno ispunjavanje obveza temelje se na načelu uravnoteženosti* (Zakona o proračunu, čl. 7.) i na načelu *dobrog financijskog upravljanja* koje kaže da se *proračunska sredstva moraju koristiti*

[44] *Izvanproračunski korisnici lokalnih jedinica jesu institucije koje ispunjavaju ova tri kriterija: lokalna jedinica ima odlučujući utjecaj na upravljanje, izvor financiranja namjenski je prihod i institucije su evidentirane u registru korisnika proračuna* (Bajo, Jurlina Alibegović 2008: 217). Sukladno Registru proračunskih i izvanproračunskih korisnika (Narodne novine 68/2015) radi se isključivo o Upravama za ceste i Županijskim upravama za ceste.
[45] Prema brutonačelu u rashodima je uvijek ukalkuliran i porez na dodanu vrijednost.
[46] Važno je napomenuti da se prilikom planiranja rashoda moraju planirati sredstva i za preuzete, a ne izvršene, obaveze iz prethodnih proračunskih godina.

u skladu s načelima dobrog financijskog upravljanja, a posebno u skladu s načelima ekonomičnosti, učinkovitosti i djelotvornosti (Zakon o proračunu čl. 11.). Načelo univerzalnosti, u osnovi, znači da bi se *svi prikupljeni prihodi trebali trošiti za sve rashode* (Zakon o proračunu, čl. 9.), ali tu postoje i određena zakonska ograničenja pa su tako komunalni prihodi (komunalna naknada i komunalni doprinos) strogo namjenski prihodi lokalnih jedinica koji se isključivo troše za održavanje ili izgradnju komunalne infrastrukture (Krmpotić 2015). *Svi se prihodi, primitci, rashodi i izdatci evidentiraju u kunama* (načelo obračunske jedinice, članak 8. Zakona o proračunu) te uz to prihodi i primitci *moraju biti raspoređeni u proračunu po ekonomskoj klasifikaciji i iskazani prema izvorima, a rashodi i izdatci proračuna moraju biti raspoređeni u proračunu prema proračunskim klasifikacijama te uravnoteženi s prihodima i primitcima* (načelo specifikacije, članak 10. Zakona o proračunu). Načelo transparentnosti (Zakon o proračunu, čl. 12.) jasno upućuje na načine objave donesenih proračunskih dokumenata bilo da se radi o donošenju proračuna, njegovim izmjenama i dopunama, odlukama o privremenom financiranju ili izvještajima o izvršenju proračuna (objava u Narodnim novinama – službenom listu Republike Hrvatske, službenim glasnicima lokalnih jedinica, internetske stranice i sl.).

Proračunske klasifikacije, sukladno Pravilniku kojega donosi ministar financija, *čine okvir kojim se iskazuju i sustavno prate prihodi i primitci te rashodi i izdatci po nositelju, cilju, namjeni, vrsti, lokaciji i izvoru financiranja* (Pravilnik o proračunskim klasifikacijama, čl. 2). One se mogu podijeliti na sljedeće vrste:

1. *organizacijska* - *sadrži povezane i međusobno usklađene (hijerarhijski i s obzirom na odnose prava i odgovornosti) cjeline proračuna i proračunskih korisnika koje odgovarajućim materijalnim sredstvima ostvaruju postavljene ciljeve* (isti Pravilnik). Primjerice, proračunska trošenja je moguće prikazati kroz popis upravnih odjela u gradskoj upravi te s njima povezanih proračunskih korisnika.
2. *ekonomska* - *sadrži prihode i primitke po prirodnim vrstama te rashode i izdatke prema njihovoj ekonomskoj namjeni* (isti Pravilnik). Najčešće je korištena klasifikacija, jer nudi detaljan prikaz prema računima kontnog plana.
3. *funkcijska* - *sadrži rashode razvrstane prema njihovoj namjeni* (isti Pravilnik).

Primjerice, rashodi se za zaštitu okoliša prema funkcijskoj klasifikaciji mogu podijeliti na:

a. gospodarenje otpadom
b. gospodarenje otpadnim vodama
c. zaštita bioraznolikosti i krajolika
d. istraživanje i razvoj.

4. <u>lokacijska</u> - *sadrži rashode i izdatke razvrstane za Republiku Hrvatsku i za inozemstvo* (isti Pravilnik).
5. <u>programska</u> - *sadrži rashode i izdatke iskazane kroz aktivnosti i projekte, koji su povezani u programe temeljem zajedničkih ciljeva* (isti Pravilnik). Primjerice, kod proračunskog korisnika Grada Osijeka, Javne profesionalne vatrogasne postrojbe, nekoliko je aktivnosti u sklopu programa rashoda za redovnu djelatnost ustanove:
    a. rashodi za plaće ustanove
    b. ostali rashodi za zaposlene ustanove
    c. materijalni rashodi ustanove
    d. financijski rashodi ustanove.
6. <u>izvori financiranja</u> - *sadrže prihode i primitke iz kojih se podmiruju rashodi i izdatci određene vrste i namjene* (isti Pravilnik). Ponovno na primjeru Javne profesionalne vatrogasne postrojbe iz Osijeka, iskazuju se rashodi financirani iz četiri osnovna izvora te je prema njima moguće i prikazati ostvarenje proračuna tog proračunskog korisnika:
    a. opći (nenamjenski) prihodi i primitci
    b. decentralizirana sredstva za vatrogastvo
    c. prihodi po posebnim ugovorima[47]
    d. *tekuće pomoći iz državnog proračuna*.

Kombinacija različitih proračunskih klasifikacija uobičajena je kod prikazivanja proračunskih ostvarenja. Naime, s pozicije financijskog upravljanja nužno je proračunsko izvještavanje prilagoditi osobama kojima su izvještaji namijenjeni, ali isto tako i olakšati procese izrade samog proračuna u dijelu zakonske usklađenosti samog proračuna.

[47] Grad Osijek ima sklopljen višegodišnji ugovor s tvrtkom A1 d. o. o. iz Zagreba o zakupu prostora za odašiljač na krovu zgrade koja je sjedište Javne profesionalne vatrogasne postrojbe. Navedena se sredstva preko proračuna usmjeravaju vatrogasnoj postrojbi.

Organizacijska klasifikacija omogućava pripremu zasebnih izvještaja svakom pojedinom pročelniku zaduženom samo za vlastiti segment poslovanja grada, ali i međusobnu usporedbu pojedinih segmenata na ukupnoj proračunskoj razini. Primjerice, izvještaj za čelnike (gradonačelnik, zamjenici i sl.) može sadržavati usporedna ostvarenja te odstupanja od planskih vrijednosti proračunskih rashoda za svaki organizacijski segment (upravni odjel). To uvelike olakšava ne samo praćenje, nego i pripremu budućih izmjena i dopuna proračuna, ali i novih proračuna. Ukoliko se želi detaljniji uvid u ostvarenja pojedinog segmenta, uz organizacijsku klasifikaciju koristi se i ekonomska klasifikacija. Ekonomska klasifikacija, kojom se rashodi razvrstavaju prema ekonomskoj namjeni omogućava, zbog svoje jednoobraznosti, jednostavnu usporedivost različitih proračuna lokalnih jedinica (npr. usporedbu rashoda za zaposlene, ulaganja u nefinancijsku imovinu i sl.).

Budući da su zakonom pojedini prihodi raspoređeni na točno određene rashode, važno je koristiti i izvore financiranja prilikom izvještavanja o proračunskim ostvarenjima, ali i kod planiranja budućih proračuna. Važno je također imati na umu da sva namjenska sredstva koja nisu potrošena u godini u kojoj su ostvarena, moraju biti *prenesena* u sljedeće proračunske godine i razmjerno utrošena. Upravna tijela gradova najčešće koriste više izvora financiranja (rijetkost su upravna tijela koja se isključivo financiraju istim, općim proračunskim prihodima), a u broju različitih vrsta izvora financiranja prednjače upravna tijela zadužena za provođenje investicijskih projekata. Iako to najčešće nije slučaj, izgradnja osnovne škole može biti financirana iz čak šest različitih izvora. Priprema zemljišta za izgradnju može biti financirana iz prodaje građevinskog zemljišta, pristupna cesta i parkiralište može biti financirano iz komunalnog doprinosa, projektiranje i sama izgradnja mogu biti financirani kreditom i decentraliziranim (državnim) sredstvima namijenjenim osnovnom školstvu, a opremanje može biti iz općih proračunskih prihoda. Ukoliko se radi o projektu koji je i energetski učinkovit, dodatni, šesti izvor financiranja dijela investicije može biti i nacionalni fond (npr. Fond za zaštitu okoliša i energetsku učinkovitost).

3.1.2. Postupak donošenja proračuna

Sam postupak pripreme i izglasavanja proračuna dugotrajan je proces koji traje prosječno oko tri mjeseca. Neovisno o razini javnog sektora koja ga donosi, prvi korak u procesu donošenja proračuna predstavlja izrada *Smjernica ekonomske i fiskalne politike*. *Na temelju strateških planova, nacionalnog programa reformi i programa konvergencije te posebnih preporuka Vijeća Europske unije za Republiku Hrvatsku, Ministarstvo financija izrađuje nacrt 'Smjernica*

ekonomske i fiskalne politike' za trogodišnje razdoblje koje Vlada usvaja zaključkom najkasnije do kraja srpnja[48] (Ministarstvo financija[49]). Navedene Smjernice koriste razni dionici kod planiranja svojih budućih aktivnosti, bilo da se radi o javnom ili privatnom sektoru te razni analitičari kod procjene kretanja gospodarstva.

Smjernice ekonomske i fiskalne politike sadrže:

1. c*iljeve ekonomske politike za trogodišnje razdoblje*
2. *makroekonomski i fiskalni okvir Republike Hrvatske*
3. *visinu financijskog plana državnog proračuna po razdjelima organizacijske klasifikacije za prethodnu i tekuću proračunsku godinu, kao i visinu financijskog plana u narednom trogodišnjem razdoblju* (Ministarstvo financija).

Visina financijskog plana po razdjelima organizacijske klasifikacije obuhvaća:

1. *visinu sredstava potrebnih za provedbu postojećih programa, odnosno aktivnosti, koje proizlaze iz trenutno važećih propisa*
2. *visinu sredstava potrebnih za uvođenje i provedbu novih ili promjenu postojećih programa, odnosno aktivnosti* (Ministarstvo financija).

Temeljem navedenih smjernica Ministarstvo financija sastavlja *upute za izradu prijedloga državnog proračuna i upute za izradu proračuna jedinica lokalne i područne (regionalne) samouprave te ih dostavlja korisnicima do 15. kolovoza tekuće godine* (Zakon o proračunu, čl. 26. i 27.).

Nakon zaprimanja uputa, *upravno tijelo za financije izrađuje upute za izradu proračuna jedinice lokalne i područne (regionalne) samouprave i dostavlja ih proračunskim i izvanproračunskim korisnicima proračuna* (članak 27. Zakona o proračunu), a one sadrže:

1. *temeljna ekonomska ishodišta i pretpostavke za izradu prijedloga proračuna jedinice lokalne i područne (regionalne) samouprave*
2. *opis planiranih politika jedinice lokalne i područne (regionalne) samouprave*
3. *procjenu prihoda i rashoda te primitaka i izdataka proračuna jedinice lokalne i područne (regionalne) samouprave u sljedeće tri godine*

[48] Smjernice ekonomske i fiskalne politike 2020. - 2022. donesene su na sjednici Vlade Republike Hrvatske 1. kolovoza 2019. godine. https://mfin.gov.hr/pristup-informacijama/publikacije/smjernice-ekonomske-i-fiskalne-politike-zavod-za-makroekonomske-analize-i-planiranje/546?trazi=1&=&page=1 (pristupljeno: 22. lipnja 2020.).
[49] https://mfin.gov.hr/proracun-86/86 (pristupljeno: 17. listopada 2020.).

4. *visinu financijskog plana po proračunskim korisnicima koja sadrži visinu financijskog plana za prethodnu proračunsku godinu i tekuću proračunsku godinu, te visinu financijskog plana za sljedeću proračunsku godinu i za sljedeće dvije godine, raspoređen na:*
    a. *visinu sredstava potrebnih za provedbu postojećih programa, odnosno aktivnosti, koje proizlaze iz trenutno važećih propisa*
    b. *visinu sredstava potrebnih za uvođenje i provedbu novih ili promjenu postojećih programa, odnosno aktivnosti.*
5. *način pripreme te terminski plan za izradu proračuna i prijedloga financijskih planova proračunskih i izvanproračunskih korisnika proračuna jedinice lokalne i područne (regionalne) samouprave* (Zakon o proračunu).

Krmpotić (2015), opisuje taj proces kako obično tijekom rujna svi sudionici proračunskog procesa pripremaju svoje prijedloge proračuna te iste na državnoj razini dostavljaju Ministarstvu financija, a na lokalnim razinama upravnom tijelu za financije. Oni razmatraju sve zaprimljene prijedloge i usklađuju financijske planove s procijenjenim prihodima i primitcima. U tom bi se trenutku trebale utvrditi i sve postojeće proračunske neusklađenosti te bi se eventualni manjkovi iz prethodnih godina trebali planski *pokriti* u budućem razdoblju. Nakon toga izrađuje se *nacrt proračuna za proračunsku godinu i projekcije za sljedeće dvije godine te se dostavlja Vladi, odnosno načelniku, gradonačelniku ili županu do 15. listopada tekuće godine* (Zakon o proračunu). Time započinje i sam postupak donošenja proračuna. Nije neuobičajeno da tijekom tog postupka još dolazi do izmjena samog prijedloga proračuna. Također, u navedenom razdoblju šira bi javnost trebala biti upoznata s nacrtom proračuna. Naime, sve je češća praksa u Republici Hrvatskoj vezana za tzv. participativno budžetiranje, odnosno da se prilikom izrade proračuna putem javnih rasprava osigura sudjelovanje građana u pripremi konačnog prijedloga proračuna. Javne rasprave uobičajeno se provode na način da se u određenom dijelu grada ili općine održi javna tribina na koju su pozvani svi građani. U posljednjih nekoliko godina, a usporedno s razvojem informatičkih tehnologija, sve se više kao alat za javnu raspravu koriste i internetske stranice lokalnih jedinica (Grad Rijeka koristi edukativnu proračunsku igru Proračun(Ajme)[50] kako bi svojim građanima omogućio da se na jednostavan način upoznaju s gradskim proračunom i da doznaju kako se proračun donosi i što obuhvaća).

[50]http://www.vojko-obersnel.com/hr/proracunaj-me/2019 (pristupljeno: 17. listopad 2020.).

Vlada, odnosno načelnik, gradonačelnik ili župan, utvrđuje prijedlog proračuna i projekcija te ih podnosi Saboru, odnosno predstavničkom tijelu, na donošenje do 15. studenoga tekuće godine (članak 37. Zakona o proračunu). Prije samo rasprave u Saboru ili predstavničkom tijelu, o podnesenom prijedlog raspravljaju i odbori predstavničkog tijela. Nakon toga, *Sabor, odnosno predstavničko tijelo, donosi proračun*[51] *na razini podskupine ekonomske klasifikacije za iduću proračunsku godinu i projekciju na razini skupine ekonomske klasifikacije za sljedeće dvije proračunske godine do konca tekuće godine i to u roku koji omogućuje primjenu proračuna s 1. siječnja godine za koju se donosi proračun* (članak 39. Zakona o proračunu).

U tablici br. 10 prikazana je razlika između skupine i podskupine ekonomske klasifikacije, odnosno vidljivo je da se detaljna razrada, u ovom slučaju, prihoda od poreza na podskupine (vrste poreza) planira i prikazuje samo za sljedeću proračunsku godinu.

Tablica 10. Prikaz skupine i podskupine ekonomske klasifikacije državnog proračuna u razdoblju od 2020. godine do 2022. godine (u 000 kuna)

Razred	Skupina	Podskupina	Naziv prihoda	Proračun za 2020.	Projekcija proračuna za 2021.	Projekcija proračuna za 2022.
6			**Prihodi poslovanja**	**144.130.276**	**147.751.821**	**151.495.404**
	61		**Prihodi od poreza**	**84.092.618**	**86.699.980**	**89.507.790**
		611	Porez i prirez na dohodak			
		612	Porez na dobit	9.349.289		
		614	Porezi na robu i usluge	74.383.403		
		615	Porezi na međunarodnu trgovinu i transakcije	359.926		

Izvor: Prikaz autora na temelju podataka Ministarstva financija Republike Hrvatske[52]

Tijekom godine, ako se utvrdi slabije prikupljanje prihoda od planirane dinamike, izmjenama bi se proračuna trebalo odmah smanjiti proračunske rashode kako ne bi došlo do nemogućnosti pravovremenog plaćanja obveza. Isto se može učiniti ako je prikupljanje prihoda bolje od očekivanja pa se otvara mogućnost trošenja dodatnih proračunskih sredstava. Važno za istaknuti je kako se sve izmjene i dopune proračuna, koje se događaju tijekom proračunske

[51] Tijekom rasprave o proračunu vrlo često se podnose amandmani na konačni prijedlog proračuna. U njima predlagatelj predlaže drukčije trošenje proračunskih sredstava od onoga predloženog u konačnom prijedlogu. O amandmanima se glasuje, te ako budu prihvaćeni postaju sastavni dio proračuna.

[52] https://mfin.gov.hr/proracun-86/drzavni-proracun-2020-godina/2981 (pristupljeno: 27. listopada 2020.).

godine, provode po postupku za donošenje proračuna i u skladu s projekcijama. Proračunska se sredstva načelno ne mogu upotrijebiti za drugačije namjene od inicijalno planiranih bez izmjena i dopuna proračuna (tzv. rebalansa proračuna), ali postoje i određene iznimke definirane zakonom (članak 46. Zakona o proračunu). *Preraspodjela sredstava na proračunskim stavkama kod proračunskih korisnika ili između proračunskih korisnika i kod izvanproračunskih korisnika može se izvršiti u iznosu od najviše do 5 % rashoda i izdataka na proračunskoj stavci donesenoj od strane Sabora, odnosno predstavničkog tijela koja se umanjuje, ako to odobri ministar financija, odnosno načelnik, gradonačelnik ili župan* (Zakon o proračunu). Dodatno, *preraspodjela sredstava može se izvršiti najviše do 15 % ako se time osigurava povećanje sredstava nacionalnog učešća planiranih u proračunu za financiranje projekata koji se sufinanciraju iz sredstava Europske unije, ako to odobri ministar financija, odnosno načelnik, gradonačelnik, župan* (Zakon o proračunu). Zbog složenosti samog postupka kreiranja proračuna, proces je prikazan i grafički na slici br. 5.

Slika 5. Postupak donošenja proračuna lokalnih jedinica vlasti

Izvor: Krmpotić (2015) na temelju Zakona o proračunu[53]

[53] Narodne novine br. 87/2008, 109/2007, 136/2012, 15/2015.

Preraspodjele se obično koriste za manje proračunske korekcije, a osobito kad se žele *pokriti* neplanirani troškovi, pa je u tablici 11 prikazano kako se preraspodjela provodi u slučaju viška sredstava na stavkama plaća za zaposlene, kada su u istom trenutku nedostatna sredstava vezana za otpremnine djelatnika.

Tablica 11. Primjer preraspodjele proračunskih sredstava proračunskog korisnika (u 000 kuna)

JAVNA PROFESIONALNA VATROGASNA POSTROJBA GRADA OSIJEKA		Postojeći iznos	Iznos nakon preraspodjele
3	**Rashodi poslovanja**	**13.965**	**13.965**
31	**Rashodi za zaposlene**	**12.099**	**12.099**
311	**Plaće (Bruto)**	**9.626**	**9.145**
3111	**Plaće za redovan rad**	**9.626**	**9.145**
31111	Plaće za zaposlene	9.626	9.145
312	**Ostali rashodi za zaposlene**	**208**	**689**
3121	**Ostali rashodi za zaposlene**	**208**	**689**
31212	Nagrade	35	35
31213	Darovi	75	75
31214	Otpremnine	16	497
31215	Naknade za bolest, invalidnost i smrtni slučaj	32	32
31216	Regres za godišnji odmor	0	0
31219	Ostali nenavedeni rashodi za zaposlene	50	50

Izvor: Krmpotić (2015) na temelju podataka Grada Osijek.[54]

U prikazanom primjeru umanjena su sredstva za plaće zaposlenika, uvećana sredstva potrebna za otpremnine zaposlenih u maksimalnom iznosu 5 %. Sredstva se mogu tijekom cijele godine prenamijeniti i izmjenama financijskog plana kad su u pitanju niže proračunske razine (4. i 5. razina) ukoliko se pri tome ne mijenja osnovna, donesena proračunska pozicija. Time je zakonski omogućena veća fleksibilnost s ciljem bržeg i učinkovitijeg korištenja proračunskih sredstava. Tablica br. 12 prikazuje spomenutu situaciju, uz dodatak da se u ovom primjeru nedostajuća sredstva potrebna za otpremnine zaposlenih *prebacuju* s više proračunskih pozicija.

U ovakvim situacijama nije potrebno paziti da se ne prelazi limit od 5 % jer na trećoj proračunskoj razini (312) nije došlo do promjene.

[54] https://www.osijek.hr/gradska-uprava/gradski-uredi-odjeli-i-sluzbe/upravni-odjel-za-financije-i-nabavu/proracunski-dokumenti/ (pristupljeno: 14. studenoga 2020.).

Tablica 12. Izmjene proračuna temeljem izmjena financijskog plana (u 000 kuna)

JAVNA PROFESIONALNA VATROGASNA POSTROJBA GRADA OSIJEKA		Postojeći iznos	Iznos nakon izmjene financ. plana
3	**Rashodi poslovanja**	**13.965**	**13.965**
31	**Rashodi za zaposlene**	**12.099**	**12.099**
311	**Plaće (Bruto)**	**9.626**	**9.626**
3111	**Plaće za redovan rad**	**9.626**	**9.626**
31111	Plaće za zaposlene	9.626	9.626
312	**Ostali rashodi za zaposlene**	**208**	**208**
3121	**Ostali rashodi za zaposlene**	**208**	**208**
31212	Nagrade	35	0
31213	Darovi	75	50
31214	Otpremnine	16	150
31215	Naknade za bolest, invalidnost i smrtni slučaj	32	0
31216	Regres za godišnji odmor	0	0
31219	Ostali nenavedeni rashodi za zaposlene	50	8

Izvor: Krmpotić (2015) na temelju podataka Grada Osijek.[55]

Nakon što predstavničko tijelo tijekom godine usvoji izmjene i dopune proračuna, čelnik lokalne jedinice ponovno na raspolaganju ima mogućnost preraspodjele sredstava do 5 % iz proračunskih stavki što uključuje i one stavke koje su mijenjane prije navedenih izmjena i dopuna.

Uz sve navedeno, zakon kaže da se sve *uplaćene i prenesene, a neplanirane pomoći, donacije, prihodi za posebne namjene i namjenski primitci od zaduživanja mogu koristiti prema naknadno utvrđenim aktivnostima i/ili projektima u proračunu uz prethodnu suglasnost Ministarstva financija, odnosno upravnog tijela za financije. Odredbe ovoga članka na odgovarajući se način primjenjuju na izvanproračunske korisnike i jedinice lokalne i područne (regionalne) samouprave* (Zakon o proračunu, čl. 50.). Ponekad predstavničko tijelo lokalne jedinice, prilikom donošenja Odluke o izvršavanju Proračuna, navedenu ovlast s upravnog tijela za financije nastoji prenijeti na čelnika lokane jedinice.

Ako Sabor, odnosno predstavničko tijelo ne donese proračun prije početka proračunske godine, privremeno se, na osnovi odluke o privremenom financiranju, nastavlja financiranje poslova,

[55] Dostupno na: https://www.osijek.hr/gradska-uprava/gradski-uredi-odjeli-i-sluzbe/upravni-odjel-za-financije-i-nabavu/proracunski-dokumenti/ (pristupljeno: 14. studenoga 2020.)

funkcija i programa državnih tijela i tijela jedinica lokalne i područne (regionalne) samouprave i drugih proračunskih i izvanproračunskih korisnika u visini koja je neophodna za njihovo obavljanje i izvršavanje te prava primatelja sredstava proračuna utvrđena zakonima i drugim propisima donesenim na temelju zakona (Zakon o proračunu). *Odluku o privremenom financiranju donosi Sabor, odnosno predstavničko tijelo, a takvo se financiranje obavlja razmjerno rashodima izvršenim u istom razdoblju prethodne godine, najviše do 1/4 ukupno izvršenih rashoda bez izdataka*[56] *te najduže za prva tri mjeseca proračunske godine* (Zakon o proračunu). U *razdoblju privremenog financiranja financiraju se isti programi, a korisnici ne smiju povećavati broj zaposlenih u odnosu na stanje 31. prosinca prethodne godine* (Zakon o proračunu). Također, *u razdoblju privremenog financiranja proračunski korisnici ne smiju preuzimati nove obveze. Nakon isteka privremenog financiranja, u tom se razdoblju ostvareni prihodi i primitci te izvršeni rashodi i izdatci uključuju u proračun tekuće godine* (Zakon o proračunu). Postoji nekoliko razloga zbog kojih može doći do opoziva odnosno razrješenja čelnika lokalnih i regionalnih jedinica ili pak do raspuštanja predstavničkih tijela. Ukoliko čelnici *ne predlože proračun predstavničkom tijelu ili povuku prijedlog prije glasovanja o proračunu u cjelini te ne predlože novi prijedlog proračuna u roku koji omogućuje njegovo donošenje, Vlada Republike Hrvatske će na prijedlog tijela državne uprave nadležnog za lokalnu i područnu (regionalnu) samoupravu razriješiti navedenog čelnika i njihove zamjenike koji su izabrani zajedno s njim* (Zakon o lokalnoj i područnoj, regionalnoj, samoupravi čl. 69. a). Nakon toga, posebnim rješenjem, *Vlada Republike Hrvatske imenovat će povjerenika Vlade za obavljanje poslova iz nadležnosti čelnika i raspisati prijevremene izbore sukladno posebnom zakonu*. Ukoliko pak predstavničko tijelo *u tekućoj godini ne donese proračun za sljedeću godinu niti odluku o privremenom financiranju te ako ne donese proračun do isteka odluke o financiranju, bit će odlukom Vlade raspušteno* (Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, čl. 84.). Ukoliko nakon ovakvih izvanrednih situacija, ponovno u zakonskom roku ne bude donesen proračun koji je predložio novoizabrani čelnik ili koji je podnesen na odlučivanje novoizabranom predstavničkom tijelu, *Vlada Republike Hrvatske istovremeno će raspustiti i predstavničko tijelo i razriješiti čelnika tijela te raspisati nove izbore* (Zakon o lokalnoj i područnoj (regionalnoj) samoupravi, čl. 85.a).

[56] Postoji i nekoliko izuzetaka a to su već ranije spomenute: *uplaćene i prenesene, a manje planirane ili neplanirane pomoći, donacije, prihodi za posebne namjene te namjenski primitci od zaduživanja.* (članak 42. Zakona o proračunu) Oni se mogu izvršavati iznad spomenute visine, ali uz prethodnu suglasnost Ministarstva financija, odnosno načelnika, gradonačelnika ili župana.

3.1.3. Proračunska transparentnost

Proračunska transparentnost ubraja se u jedno od osnovnih proračunskih načela. Zakonom o proračunu definirano je da država, ali i lokalne odnosno regionalne jedinice, trebaju redovito izvještavati javnost o svojim financijskim ostvarenjima i planovima za buduća razdoblja. Ministarstvo financija objavljuje podatke za državni proračun, ali i dio podataka o poslovanju svih općina, gradova i županija u Republici Hrvatskoj temeljem predanih godišnjih izvještaja (npr. ne objavljuju se podatci iz izvještaja o obvezama).

Gradovi, kao i općine te županije imaju obvezu pripreme kvartalnih, polugodišnjih i godišnjih izvještaja i predaje istih u Financijsku agenciju. Radi se o nekoliko standardiziranih izvještaja:

1. PR-RAS - izvještaj o proračunskim prihodima i rashodima
2. BIL - izvještaj o stanju bilance na dan izrade izvještaja
3. RAS-F - izvještaj o rashodima prema funkcijskoj klasifikaciji
4. P-VRIO - izvještaj o promjenama u vrijednosti i obujmu imovine i obveza
5. OBVEZE - izvještaj o obvezama u promatranom razdoblju.

Rok za predaju godišnjeg izvještaja je 15. veljače tekuće godine za prethodnu godinu, a za kvartalne i polugodišnji izvještaj 10 dana nakon isteka izvještajnog razdoblja ili prvi sljedeći radni dan ukoliko je 10. dan, neradni dan. Najkasnije osam dana od predaje izvještaja, postoji zakonska obveza objave tih izvještaja na vlastitim internetskim stranicama ili stranicama nadležne jedinice regionalne samouprave ukoliko nemaju vlastitu stranicu.

Postoji obveza predaje i konsolidiranih izvještaja ako postoji više povezanih proračunskih korisnika. Kod gradova je to uobičajeno, jer u pravilu svi imaju proračunske korisnike iz područja obrazovanja, sporta, kulture i vatrogastva. Rok za predaju te vrste izvještaja je 28. veljače tekuće godine za prethodnu godinu.

Osim obveznih izvještaja, gradovi pripremaju godišnji i polugodišnji izvještaj o izvršenju proračuna te ih čelnik tijela predaje nadležnom gradskom vijeću na usvajanje. Isti je postupak i s donošenjem Proračuna i svim izmjenama i dopunama. Svi navedeni dokumenti objavljuju se u službenim glasnicima gradova.

Naravno, iako je zakonom definirano postupanje po pitanju objave financijskih izvještaja, njihove strukture i dinamike objava, važno je naglasiti da je to samo minimum onoga što predstavlja transparentnost jednog grada kad je u pitanju proračun i proračunsko trošenje.

Naime, transparentnost svaki čelnik grada tumači na svoj način, ali oni najtransparentniji gradovi objavljuju još detaljnije podatke o svim proračunskim prihodima i rashodima ili objavljuju češće nego je to zakonom propisano. Na primjer, zakonom je definirano da se rashodi u trenutku donošenja proračuna prikazuju na razini podskupine ekonomske klasifikacije (na *trećoj* proračunskoj razini), ali transparentni gradovi zainteresiranoj javnosti i gradskim vijećnicima ili zastupnicima u skupštini dodatno prikazuju još detaljnije podatke odnosno podatke na razini osnovnog računa (na *petoj* proračunskoj razini).

Mnogi gradovi provode i javne rasprave oko budućih prijedloga proračuna i kreiraju vodiče za građane kako bi im pojednostavnili i značajno približili podatke o trošenju njihova novca. Dodatno, sve je veći broj gradova koji transparentno objavljuju svoje postupke nabave usluga, roba i radova koji prethode dijelu proračunskog trošenja te koji objavljuju podatke o svim pojedinim isplatama prema pravnim osobama (omogućena pretraga javnih baza prema dobavljačima). Nažalost, rijetko se objavljuju podatci o kašnjenju u plaćanju obveza gradova ili o dospjelim, neplaćenim obvezama, a kad se i objave budu u *šumi* svih ostalih podataka te ih prosječan građanin teško zamijeti.

Postoje i institucije, primjerice Institut za javne financije, koje dugo godina provode aktivnosti na poticanju i promicanju proračunske transparentnosti te koje isticanjem i nagrađivanjem dobre prakse pojedinih gradova potiču sve ostale gradove na veće zalaganje po ovom pitanju. Sve navedene aktivnosti daju građanima veći osjećaj sigurnosti da se njihova sredstva troše racionalno.

3.1.4. Proračun i fiskalna politika

Fiskalna politika predstavlja skup mjera neke države kojima se utječe na dohotke, imovinu i akumulaciju fizičkih i pravnih osoba radi prikupljanja sredstava za financiranje javne potrošnje, a korištenjem fiskalnih instrumenata (poreza, javnih rashoda, javnog duga) država utječe na pojedine ciljeve ekonomske politike (Baletić 238: 1995). Osnovi alat fiskalne politike je proračun, kako državni tako i proračuni na svim ostalim razinama vlasti. Budući da je Republika Hrvatska članica Europske unije i budući da je po mnogim pokazateljima ispod prosjeka zemalja članica, Vlada Republike Hrvatske izradila je i predstavila Europskoj komisiji Nacionalni program reformi te svake godine izrađuje Program konvergencije[57] Republike

[57] *Program konvergencije opisuje makroekonomska i fiskalna kretanja te izglede u narednom razdoblju, a definira i planove za osiguravanje srednjoročne održivosti javnih financija. Ovaj dokument ujedno predstavlja i makro-fiskalni okvir reformskih mjera opisanih u Nacionalnom programu reformi* (Smjernice ekonomske i fiskalne politike za period 2020. - 2022. godine).

Hrvatske za buduće četverogodišnje razdoblje. Program konvergencije predstavlja fiskalni okvir u budućem razdoblju i temelj je za izradu Smjernica ekonomske i fiskalne politike, a sadrži - *prikaz srednjoročnog proračunskog okvira (projekcija općeg proračuna i javnog duga), fiskalne rizike i analizu osjetljivosti kretanja manjka, odnosno viška općeg proračuna i javnog duga te održivost i kvalitetu javnih financija* (Zakon o proračunu). Republika Hrvatska ima obvezu pridržavati se fiskalnih pravila definiranih na razini Europske unije, ali uslijed epidemije bolesti COVID-19 (SARS-Cov-2) koja je započela u proljeće 2020. godine na razini Europske unije, donesena je odluka o privremenom odgađanju primjene fiskalnih pravila, odnosno pravila strukturnog salda[58], pravila rashoda i pravila javnog duga kako bi se zaštitilo gospodarstvo te očuvala radna mjesta.

Fiskalna politika Republike Hrvatske uobičajeno je usmjerena prema procesima jačanja upravljanja proračunom i održivosti javnih financija s ciljem održavanja ekonomskog rasta. Jedan od ključnih pokazatelja je smanjenje udjela duga opće države u BDP-u, ali i racionalna proračunska potrošnja koja je dovela do proračunskog viška opće države u prijašnjim godinama. *Empirijski je dokazano da mogućnost pozitivnog djelovanja fiskalne politike na BDP postoji, ali da bi fiskalna politika bila što učinkovitija trebalo bi se pridržavati preciznih mjera koje su prethodno formulirane kao mjere pametne fiskalne konsolidacije* (Šimović i suradnici 2014). *Doprinos fiskalne politike poticanju ekonomskog rasta vidljiv je dakle kroz provođenje strukturnih (poreznih) reformi te usmjeravanju proračunskih sredstava u razvojna područja. Također, trebalo bi i dalje sredstva usmjeravati prema obrazovanju i znanosti te nastaviti reformirati mirovinski, zdravstveni i sustav socijalnog osiguranja* (Družić i Krtalić 2006).

Na slici br. 6 vidljivo je kontinuirano smanjivanje javnog duga mjerenog postotkom BDP-a od 2015. godine do 2019. godine, pri čemu se, zbog krize uzrokovane epidemijom, očekuje porast navedenog udjela u iznosu od 13,5 % u 2020. godini.

[58] *Strukturni saldo je manjak odnosno višak općeg proračuna koji isključuje cikličke ekonomske učinke, jednokratne i privremene mjere koje imaju utjecaj na prihode odnosno rashode općeg proračuna. Strukturni saldo izračunava se sukladno pravnim odredbama Europske unije* (članak 5. zakona o fiskalnoj odgovornosti, NN 111/2018, 41/2020).

Slika 6. Pregled kretanja javnog duga do 2021. godine

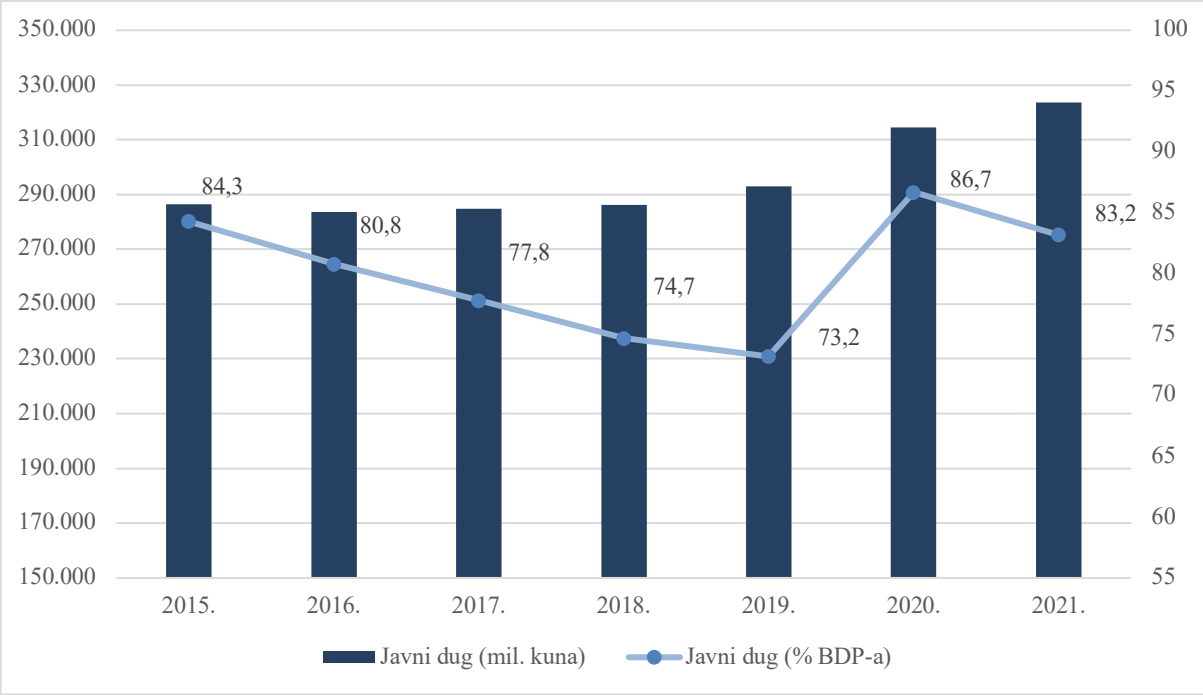

Izvor: Prikaz autora na temelju Programa konvergencije Republike Hrvatske za 2020. i 2021. godinu (travanj 2020.)[59]

Kako bi se proračunima upravljalo odgovorno i u skladu s opisanim okvirima od strane čelnika, stvoren je zakonodavni okvir putem Zakona o fiskalnoj odgovornosti. Zakon o fiskalnoj odgovornosti prvi je put uveden 2010. godine te mu je osnovna svrha bila određivanje *pravila kojima bi se ograničila državna potrošnja, pojačala odgovornost za zakonito, namjensko i svrhovito korištenje proračunskih sredstava te pojačao sustav kontrola i nadzora radi osiguranja fiskalne odgovornosti* (članak 1. Zakona). Navedene odgovornost čelnik tijela preuzima i potvrđuje, tada uvedenom, Izjavom o fiskalnoj odgovornosti, ali njome čelnik potvrđuje *i učinkovito i djelotvorno funkcioniranje sustava financijskog upravljanja i kontrola unutar proračuna*. Dodatno, Zakon je definirao da se primjerice *visina deficita i neto zaduživanja za trogodišnje razdoblje utvrđuje Smjernicama ekonomske i fiskalne politike* (članak 8. Zakona).

Važno je napomenuti da navedena pravila vrijede, *kako za državni proračun i proračune lokalnih i regionalnih jedinica vlasti, tako i za proračunske korisnike te trgovačka društva u javnom vlasništvu* (Zakon o fiskalnoj odgovornosti).

[59]https://vlada.gov.hr/UserDocsImages/2016/Sjednice/2020/Travanj/227%20sjednica%20VRH/Novi%20direktorij/227%20%202%20Program %20konvergencije %20Republike %20Hrvatske %20za %202020. %20i %202021. %20godinu.pdf (pristupljeno: 8. studenoga 2020.).

Naime, sve zakonodavne aktivnosti centralne vlasti usmjerene su prema postizanju zadanih ciljeva te poštivanju postojećih fiskalnih pravila.

Novi Zakon o fiskalnoj odgovornosti donesen je 2018. godine. U njemu je, između ostalog, u Zakon uveden dio vezan za Povjerenstvo za fiskalnu politiku[60]. Nadalje, odlukom Sabora iz 2013. godine, prvi je put osnovano takvo stručno, neovisno i savjetodavno tijelo. Već je tada definirano da su članovi tijela predstavnici Državnog ureda za reviziju, Ekonomskog instituta Zagreb, Instituta za javne financije te ekonomskih i pravnih fakulteta te da njihov rad ima za cilj unaprjeđenje sustava javnih financija kao i praćenje primjene fiskalnih pravila utvrđenih Zakonom o fiskalnoj odgovornosti.

3.2. Obveze i odrednice vjerojatnosti neplaćanja

Gradovi u Republici Hrvatskoj imaju stabilan izvor prihoda i jasno definirane ovlasti i s tim ovlastima povezane rashode (primjerice održavanja infrastrukture, sredstva namijenjena kulturi, predškolskom odgoju ili troškovi gradske administracije). Dodatno, gradovi imaju imovinu velike vrijednosti te najčešće jednostavan pristup i apsorpciju povoljnih kreditnih sredstava što gradove stavlja u povoljan položaj kad su u pitanju mogućnosti plaćanja svih vrsta nastalih obveza. Nemogućnost plaćanja može nastati zbog nedostatnih sredstava na poslovnom računu za plaćanje dospjelih obveza ili zbog ovrhe na poslovnom računu čija vrijednost nadmašuje vrijednost sredstava na računu. Osnovni prihodi, sukladno zakonskim propisima, trebali bi biti dovoljni za pokrivanje osnovnih funkcija koje su dodijeljene lokalnim i regionalnim jedinicama vlasti. Poreznim i drugim općim[61] proračunskim prihodima, *grubo* rečeno, propisano je (su)financiranje: obrazovanja, kulture, sporta, zdravstva, socijalne skrbi, gospodarstva, projekata iz nacionalnih i EU fondova, otplata kredita te rad gradske uprave. Namjenskim prihodima (komunalna naknada, naknada za uređenje voda, komunalni doprinos, spomenička renta i sl.) propisano je financiranje održavanja i izgradnje imovine gradova (npr. komunalna infrastruktura), dok bi se veliki investicijski projekti trebali financirati kreditnim sredstvima, pomoći ili u fazama iz tekućih proračunskih prihoda.

[60] https://mfin.gov.hr/proracun-2020/povjerenstvo-za-fiskalnu-politiku/613 (pristupljeno: 22. lipnja 2020.).

[61] *Opći prihodi i primitci predstavljaju prihode koji se ostvaruju temeljem posebnih propisa u kojima za prikupljene prihode nije definirana namjena korištenja, a to su: prihodi od poreza, prihodi od financijske imovine, prihodi od nefinancijske imovine, prihodi od administrativnih (upravnih) pristojbi, prihodi državne uprave, prihodi od kazni te primitci od financijske imovine i zaduživanja za koje nije definirana namjena korištenja* (članak 18. Pravilnika o proračunskim klasifikacijama).

Neuravnoteženost svake od navedenih skupina može dovesti do nenamjenskog trošenja proračunskih sredstava koja je onda, u budućim proračunskim razdobljima, potrebno *vratiti*. Primjerice, ukoliko se ne ostvari planirana razina općih prihoda (najčešće zbog nerealnih planova), a zadrži se dinamika realizacije planiranih rashoda dolazi do stvaranja manjka. Ako se u isto vrijeme namjenski prihodi ne utroše u potpunosti, može se pojaviti situacija u kojoj nije stvoren ukupni proračunski manjak, ali je manjak općih prihoda *pokriven* viškom namjenskih prihoda. Ukoliko se ovakve situacije nesrazmjera prihoda i rashoda učestalo ponavljaju te potraju dulje, one mogu dovesti i do nemogućnosti plaćanja obveza.

Nemogućnost plaćanja, iz pozicije lokalnih jedinica vlasti može nastupiti zbog nekoliko osnovnih razloga, a to su:

1. pad proračunskih prihoda
2. prekomjeran rast troškova
3. loše upravljanje imovinom
4. neracionalno upravljanje dugom
5. loše upravljanje novčanim tijekom
6. sudske presude.

Pad proračunskih prihoda najčešće je rezultat zakonskih izmjena. Naime, iako je brojnim zakonima, a osobito Europskom poveljom, definirano da prihodi trebaju biti razmjerni odgovornostima koje lokalna vlast ima, u zadnjih 10 godina bilo je značajnih zakonodavnih promjena koje su imale i pozitivne i negativne učinke na visinu i strukturu prihoda gradova s obzirom na to da su zakonima definirani i propisani najveći pojedinačni prihodi lokalnih jedinica, negativne promjene u zakonskom smislu mogu u najkraćem roku nepovoljno djelovati i istodobno izazvati nemogućnost plaćanja lokalnih jedinica. U tablici 13. prikazane su oscilacije u ukupnim prihodima od poreza. Naime, 2015. godine dogodila se porezna reforma koja je bila usmjerena na porezno rasterećenje dohotka građana (povećan je osobni odbitak s 2.200 kuna na 2.600 kuna i promijenjeni su porezni razredi) kako bi se stimulirala osobna potrošnja i povećao BDP. Budući da su izostale kompenzacijske mjere Vlade Republike Hrvatske, gradovima su smanjeni prihodi od poreza i prireza na dohodak za milijardu kuna. Sljedeća reforma koja je značajnije utjecala na pad proračunskih prihoda gradova dogodila se 2017. godine kada je dodatno smanjeno opterećenje dohotka građana (osobni odbitak povećan je na 3.800 kuna), ali je pad prihoda od gotovo pola milijarde kuna kompenziran izravnom državnom pomoći u visini navedenog pada.

Tablica 13. Pad proračunskih prihoda gradova temeljem zakonskih izmjena u periodu od 2014. do 2017. godine (u 000 kuna)

Rč.	Opis stavke	2014.	2015.	2016.	2017.
6	PRIHODI POSLOVANJA	14.988.867	14.435.713	15.144.496	15.188.542
61	Prihodi od poreza	9.473.767	8.590.430	9.178.703	8.766.169
611	Porez i prirez na dohodak	8.653.156	7.696.667	8.228.398	7.769.193
613	Porezi na imovinu	524.676	589.437	632.498	772.122
614	Porezi na robu i usluge	295.871	302.998	316.186	221.383
616	Ostali prihodi od poreza	63	1.328	1.621	3.470
63	Pomoć iz inozemstva i od subjekata unutar općeg proračuna	1.223.014	1.440.335	1.539.680	1.911.685
633	Pomoć proračunu iz drugih proračuna	650.357	656.822	646.830	1.130.040

Izvor: Prikaz autora na temelju podataka Ministarstva financija Republike Hrvatske.[62]

Pad proračunskih prihoda mogu izazvati negativni demografski i gospodarski trendovi. Pad broja stanovnika, pad broja zaposlenih ili snižavanje prosječne plaće negativno se odražava na proračunske prihode. Pad broja stanovnika, posljedično i broja kućanstava (uz jednak broj zaposlenih i prosječnu razinu plaće) smanjuje bazu onih koji plaćaju komunalne usluge te se navedene usluge moraju u većoj mjeri subvencionirati (npr. odvoz kućnog smeća ili gradski prijevoz) ili se održavanje postojeće razine usluge mora financirati iz drugih izvora (komunalna naknada). Pad broja zaposlenih ili snižavanje prosječne razine plaća smanjuje broj građana koji plaćaju porez iz svojih dohodaka, a istodobno i povećavaju broj građana koji nije u mogućnosti redovito plaćati ostale obveze prema gradovima. Cijeli koncept fiskalnog izravnanja temelji se na ovakvim trendovima i pokušaju ublažavanja njihovih posljedica. Pad prihoda može biti i posljedica želje za poticanjem gospodarstva i/ili kupovne moći građana, pa se čelnik neke lokalne jedinice može odlučiti na prekomjerno smanjivanje lokalnih poreza (npr. prirez porezu na dohodak) ili nekih naknada (komunalni doprinos ili komunalna naknada), ali može biti i posljedica lošeg upravljanja potraživanjima za prihode poslovanja (npr. nepravodobno provođenje ovrha).

Rast troškova može dovesti do nemogućnosti podmirenja obveza na vrijeme i u potpunosti. U najvećoj se tu mjeri radi o potencijalnom porastu materijalnih troškova i troškova zaposlenih, ali i o porastu potrebe za subvencijama trgovačkim društvima[63] u vlasništvu lokalnih jedinica.

[62]https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/pr-ras-i-ras-funkc-za-razdoblje-2014-2018/208 (pristupljeno: 27. listopada 2020.).
[63] U pravilu najviši iznosi vezani su za subvencije prijevoza i sportskih objekata.

Ove pozicije često porastu te budu neusklađene sa stvarnim proračunskim prihodima zbog izvršavanja predizbornih obećanja danih građanima, ali jednako tako i zbog određenih nepredviđenih okolnosti (npr. rast troškova energenata). Troškovi određene investicije mogu porasti zbog nužnih, a investicijom nepredviđenih radova. Najčešće do njih dolazi prilikom rekonstrukcije postojećih, starijih objekata (zgrada ili komunalna infrastruktura), jer je prije početka radova teško predvidjeti dotrajalost i ukupne razmjere potrebnih radova. Također, kod investicijskih projekata može doći i do promjene strukture financiranja zbog koje, u danom trenutku, može porasti trošak financiran iz proračunskih prihoda gradova (npr. neprihvatljivi troškovi nekog projekta koji je sufinanciran sredstvima nacionalnih ili EU fondova).

Gradovi raspolažu s velikom i vrlo vrijednom imovinom u koju se ubrajaju stambeni objekti (iznajmljeni socijalno ugroženim građanima), sportski i poslovni objekti, zemljišta (građevinska, poljoprivredna i sl.), komunalna infrastruktura te javne površine. Loše upravljanje tom imovinom, primjerice velik broj neiznajmljenih stambenih i poslovnih objekata, može dovesti do značajnog pada prihoda te se posljedično negativno odraziti na nemogućnost plaćanja obveza. Također, neadekvatno održavanje svih tih objekata može dovesti do povećane potrebe za ulaganjima i porasta te vrste troškova.

Postoje zakonska ograničenja u smislu dugoročnog zaduživanja, što jednim dijelom smanjuje rizik neplaćanja obveza, ali visoka kreditna zaduženost, u slučaju negativnih gospodarski kretanja te pada osnovnih proračunskih prihoda, može zahtijevati da se veći dio proračuna odvaja za plaćanje obveza po kreditima i time onemogućiti plaćanje dijela drugih redovnih troškova. Također, jednokratno dospijeće dugoročnog duga može lokalnu jedinicu dovesti u značajne probleme ukoliko se na vrijeme ne osiguraju sredstva za otplatu ili se ne osigura refinanciranje obveze. Dodatno, visok dug ustanova kojima su lokalne jedinice osnivači i trgovačkih društava u njihovom vlasništvu može dovesti do nemogućnosti plaćanja tih subjekata te potrebe za intervencijom lokalne jedinice. Važno je istaknuti i da prekomjerno i neadekvatno korištenje kratkoročnog zaduživanja (npr. ako se kratkoročnim dugom financiraju povećani materijalni rashodi) može dovesti do velikih poremećaja u funkcioniranju lokalnih jedinica jer kratkoročni dug, u zakonskom smislu, nije moguće refinancirati. Novčani je tijek lokalnih jedinica u pravilu dosta stabilan, ali postoje situacije koje mogu značajno narušiti tu stabilnost kao što su povrat poreza građanima, ulaganja iz namjenskih proračunskih prihoda ili predfinanciranje projekata sufinanciranih iz nacionalnih fondova i fondova Europske unije.

Povrat preplaćenog poreza iz prethodne godine građanima se vraća sredinom tekuće godine i tijekom tog razdoblju, s obzirom na način samog povrata koji vrši država, lokalne jedinice nemaju poreznog prihoda s osnove svog najvažnijeg prihoda. Nedovoljno naplaćen namjenski prihod (npr. prihod od komunalnog doprinosa) uz realizaciju investicija planiranih iz navedenog izvora, mogu dovesti grad u situaciju da se investicija ne može platiti na vrijeme, ukoliko nije osigurano zamjensko financiranje. Predfinanciranje projekata također može značajno narušiti novčani tijek budući da proces odobravanja i isplate povrata uloženih sredstava predstavlja često kompliciran i dugotrajan proces. Budući da je ponekad riječ o velikim infrastrukturnim ulaganjima, odgađanje povrata ili čak djelomično ustezanje isplate zbog proceduralnih pogrešaka može lokalnu jedinicu dovesti u ozbiljne financijske probleme.

Ista se situacija može dogoditi kod okončanja dugotrajnih sudskih postupka gdje je ishod neizvjestan, a sudski troškovi i kamate značajno premašuju iznos glavnice spora te se u trenutku izvršnosti presude lokalne jedinice mogu naći u situaciji nemogućnosti plaćanja. Dobar je primjer dugotrajni sudski spor kojeg vodi Javna ustanova *Zbrinjavanje otpada istočne Slavonije* (ZOIS) čiji su osnivači pet slavonskih gradova (Osijek, Beli Manastir, Vinkovci, Vukovar i Županja) s tvrtkama Strabag i Saubermacher. Spor je nastao nakon raskidanja ugovora za izgradnju regionalnog odlagališta otpada, a sama izgradnja nikada nije ni započela te navedene tvrtke potražuju izgubljenu dobit. Sudski postupci traju dulje od desetljeća te je krajem 2019. vrijednost sporova premašivala 100 milijuna kuna. Ukoliko gradovi izgube navedeni spor, ovrha na njihovim računima onemogućit će njihovo redovito funkcioniranje.

3.2.1. Financijske i nefinancijske obveze

Obveze koje, smanjenim prihodima, provedenim aktivnostima ili izvanrednim okolnostima, mogu nastati, prema vrsti obveza dijelimo na financijske i nefinancijske, a prema dospjelosti obveza na dospjele i nedospjele. Financijska obveza definirana je kao *svaka ugovorna obveza da se isporuči novac ili druga financijska imovina, razmjeni financijska imovina ili financijske obveze te i kao ugovor koji će se podmiriti ili se može podmiriti vlastitim vlasničkim instrumentom* (Hrvatski standardi financijskog izvještavanja[64]). Kad su u pitanju gradovi, financijske obveze sastoje se od: *obveza za financijske rashode, obveza za vrijednosne papire te obveza za kredite i zajmove*, a među financijske rashode ubrajaju se: *rashodi za kamate za izdane vrijednosne papire, kamate na primljene kredite i zajmove te obveze za ostale financijske rashode (obveze za bankarske usluge i usluge platnog prometa, obveze za negativne tečajne*

[64] Odluka o objavljivanju Hrvatskih standarda financijskog izvještavanja (Narodne novine br. 86/2015, 105/2020).

razlike, obveze za zatezne kamate i troškove faktoringa) (Pravilnik o proračunskom računovodstvu i računskom planu). Evidentirane obveze za kamate obično se javljaju u situaciji u kojoj glavnica, primjerice, dospijeva na zadnji dan u mjesecu, te se tada vrši i obračun kamata, a dospijeće plaćanja može biti na neki kasniji datum. Obveze za vrijednosne papire dijele se na tuzemne i inozemne te se one sastoje od: obveza za čekove, trezorske zapise, mjenice, obveznice, opcije i druge financijske derivate, te ostale vrijednosne papire. Obveze za kredite i zajmove također se dijele na tuzemne i inozemne te se dijele prema vrsti kreditora na:

1. *međunarodne organizacije, institucije i tijela EU, inozemne vlade*
2. *kreditne i ostale financijske institucije u javnom sektoru*
3. *trgovačka društva u javnom sektoru*
4. *kreditne i ostale financijske institucije izvan javnog sektora*
5. *trgovačka društva i obrtnici izvan javnog sektora*
6. *druge razine vlasti* (Pravilnik o proračunskom računovodstvu i računskom planu).

Nefinancijskim obvezama smatraju se obveze za rashode poslovanja (iz kojih su isključene već navedene obveze za financijske rashode) i obveze za nabavu nefinancijske imovine. Nefinancijske obveze za rashode poslovanja sastoje se od: obveza za zaposlene (obveze za naknade plaća, porez, prirez, doprinose, prigodne nagrade i sl.), obveza za materijalne rashode (rashodi za materijal i energiju, rashodi za usluge, naknade troškova zaposlenima, naknade troškova osobama izvan radnog odnosa i sl.), obveza za subvencije (trgovačkim društvima u javnom sektoru te fizičkim i pravnim osobama izvan javnog sektora), obveza za povrat primljene pomoći, obveza za naknade građanima i kućanstvima, obveza za kazne, penala i naknadi šteta te ostalih tekućih obveza (obveze za poreze, više uplaćene doprinose, predujmove, primljene jamčevine i sl.).

Obveze za nabavu nefinancijske imovine sastoje se od: obveza za nabavu ne proizvedene dugotrajne imovine (materijalne kao što su zemljišta i rudna bogatstva te nematerijalne kao što su patenti, koncesije, licence i sl.), obveza za nabavu proizvedene dugotrajne imovine (građevinski objekti, postrojenja i oprema, prijevozna sredstva i sl.), obveza za plemenite metale, nabavu zaliha te dodatnih ulaganja na nefinancijskoj imovini.

3.2.2. Dospjele i nedospjele obveze

Ukoliko obveza nije podmirena nakon datuma označenog kao valuta plaćanja, obveza se smatra dospjelom (Bajo 2007: 4). Podjela obveza na dospjele i nedospjele obveze vezana je u

prvom redu uz način ugovaranja poslovnih odnosa, a onda i za trenutak plaćanja istih. Naime, obveze bi se, u pravilu, trebale plaćati *odmah po zaprimanju urednog računa, a najkasnije u roku 30 dana od zaprimanja* - sukladno članku 12. Zakona o financijskom poslovanju i predstečajnoj nagodbi[65]. Ugovorom, narudžbenicom ili općim uvjetima poslovanja, ako su u pitanju standardizirane usluge (usluge opskrbe pitkom vodom, plinom, grijanja i sl.), ugovara se točan rok isporuke usluge i rokovi plaćanja. Nakon isteka toga roka, ako račun nije plaćen, odveza se smatra dospjelom. Dospjele obveze obično se klasificiraju u skupine ovisno o vrsti obveze (obveza za rashode poslovanja, obveza za nabavu nefinancijske imovine, obveze za financijsku imovinu i sl.) i duljini prekoračenja roka:

1. *prekoračenje 1 do 60 dana*
2. *prekoračenje 60 do 180 dana*
3. *prekoračenje 181 do 360 dana*
4. *prekoračenje preko 360 dana* (Izvještaj o obvezama).

Vrlo je čest slučaj da lokalne jedinice, na kraju kalendarske i proračunske godine, ali i na kraju svakog izvještajnog razdoblja (svaki kvartal) imaju određeni iznos neplaćenih, dospjelih obveza. Naime, svaki se čelnik trudi na vrijeme platiti plaće zaposlenicima, ali plaćanje ostalih obveza nije uvijek tako ažurno. Ukoliko neplaćanje obveza nije uzrokovano dugotrajnim nedostatkom likvidnih sredstava, uglavnom su dospjele obveze vezane za materijalne rashode za izvršene usluge te za režijske troškove koji, u pravilu, imaju kraće rokove dospijeća (npr. račun za javnu rasvjetu u većem gradu može iznositi i nekoliko stotina tisuća kuna, a sama procedura provjere i plaćanja računa može potrajati dulje od predviđenog, kratkog roka plaćanja). Može se, naravno, dogoditi i propust u praćenju valute plaćanja svih onih koji sudjeluju u *lancu odlučivanja* prilikom odobravanja nekog računa, ali može doći i do osporavanja dijela prispjelog računa (za dio usluga ili radova koja nije izvršena), što sve može produljiti rok plaćanja te obveza može dospjeti. Nedospjele se obveze također sastoje od istih skupina vezanih za vrstu obveze s tim da kod nedospjelih obveza u pravilu visinom prednjače obveze za financijsku imovinu jer se one sastoje od svih budućih otplata glavnice po kreditima.

[65] Zakon o financijskom poslovanju i predstečajnoj nagodbi (Narodne novine 108/2012, 144/2012, 81/2013, 112/2013, 78/2015 i 71/2015).

3.3. Zaduživanje i dug

Prema Krmpotiću (2015), izvori sredstava za financiranje tekućih i investicijskih izdataka lokalnih jedinica vlasti, mogu biti vrlo različiti. Osim onih uobičajenih poreza i naknada koje građani i tvrtke uplaćuju u lokalne proračune te transfera s državne razine kojima se financiraju decentralizirane funkcije[66], vrlo su bitan izvor i primitci od zaduživanja. *Prema načelu ostvarenih koristi korisnici određenog programa državne potrošnje trebaju za njega i platiti odnosno ako program stvara koristi budućim generacijama, onda bi putem kreditnog financiranja bilo opravdano prebaciti teret na buduće generacije* (Rosen i Gayer 2010: 469). Lokalne jedinice mogu, u određenim situacijama, zaduživanjem uskladiti proračunske prihode i rashode odnosno sredstva iskoristiti za likvidnost ili investicijski projekt. U pravilu, takva sredstva za njih osiguravaju različite kreditne institucije, a zakonom je definirano da se kao kreditne institucije (pritom poštujući i ostale zakonske odredbe) mogu osnovati:

1. *banke*
2. *štedne banke*
3. *stambene štedionice* (Zakon o kreditnim institucijama[67]).

Gradovi se zadužuju kod poslovnih i razvojnih banaka (npr. Hrvatska banka za obnovu i razvoj, (HBOR), Europska banka za obnovu i razvoj (EBRD) ili Europska investicijska banka (EIB)). Zakon kaže *da se jedinica lokalne i područne (regionalne) samouprave može zaduživati uzimanjem kredita, zajmova i izdavanjem vrijednosnih papira* (Zakon o proračunu, čl. 86.).

3.3.1. Vrste zaduživanja

Financijske institucije gradovima omogućavaju kreditna zaduživanja te izdavanje dužničkih vrijednosnih papira putem tržišta kapitala. Dodatno, pružaju im usluge otkupa potraživanja te financijskog *leasinga*, ali omogućuju i da putem jamstava i suglasnosti za zaduživanje osnaže dužničku poziciju svojih trgovačkih društava i ustanova prilikom zaduživanja. Stoga se osnovne vrste zaduživanja gradova mogu podijeliti na:

1. kredit
2. municipalne obveznice
3. *faktoring* u funkciji kratkoročnog zaduživanja
4. financijski *leasing*

[66] Školstvo, zdravstvo, socijalna skrb i vatrogastvo
[67] Zakon o kreditnim institucijama (Narodne novine 159/2013, 19/2015)

5. jamstva
6. suglasnosti za zaduženje.

Kredit je ustupanje određene svote novčanih sredstava od strane financijske organizacije (banke i dr.) kao kreditora (vjerovnika, zajmodavca) nekoj osobi (debitoru, dužniku, zajmoprimcu) uz obvezu da mu ju ova vrati u dogovorenom roku i plati pripadajuću naknadu – kamatu (Leko, Mates 1993: 247). Krediti se prema duljini trajanja mogu podijeliti na:

1. *kratkoročne kredite (krediti sa rokom trajanja do godine dana)*
2. *srednjoročne kredite (odobravaju se sa rokom trajanja od jedne do tri godine te služe za nabavu opreme i manja investicijska ulaganja)*
3. *dugoročne kredite (odobravaju se na rok dulji od tri godine te služe za financiranje investicija)* (Matić 2011: 227).

Zakon definira *da se jedinica lokalne i područne (regionalne) samouprave može kratkoročno zadužiti najduže do 12 mjeseci te samo za premošćivanje jaza nastalog zbog različite dinamike priljeva sredstava i dospijeća obveza* (Zakon o proračunu, čl. 86.a). *U praksi, lokalne jedinice najčešće uzimaju kratkoročne kredite po revolving*[68] *principu kojima se ublažavaju 'udari' na likvidnost u mjesecima kad su slabiji priljevi sredstava ili pak u mjesecima velikih odljeva proračunskih sredstava* (Krmpotić 2015). Primjerice, u Gradu Osijeku najveće se neusklađenosti priljeva i odljeva pojavljuju u drugom kvartalu kada se građanima vrši povrat više uplaćenog poreza i prireza na dohodak temeljem podnesene godišnje prijave (do 15 % mjesečnog priljeva se tada vraća građanima) i u zadnjem kvartalu te na prijelazu iz jedne u drugu proračunsku godinu kada u najvećem dijelu dospijevaju na naplatu računi za održavanje i izgradnju komunalne infrastrukture. Već se u sljedećem članku zakona dodatno ističe *da se jedinica lokalne i područne (regionalne) samouprave može dugoročno zadužiti samo za investiciju*[69] (Zakon o proračunu, čl. 87.). Iako zakonodavac nije napravio razliku između srednjoročnog i dugoročnog kredita, s obzirom na troškove zaduživanja (i rast ukupnog troška

[68] *Revolving kredit je ugovor prema kojem kreditor stavlja na raspolaganje određeni okvirni iznos novca što ga uzimatelj kredita može iskoristiti u bilo kojem trenutku u obliku kontinuiranih kratkoročnih kredita. Revolving kredit ima ugovorenu gornju granicu novčanih iznosa koji se stavljaju na raspolaganje. Svako korištenje sredstava smanjuje iznos novca koji ostaje na raspolaganju, a vraćanje kredita obnavlja iznos do gornjeg okvirnog iznosa. Za takvo osiguranje sredstava banka zaračunava naknadu koju je korisnik dužan plaćati i kad se ne koristi odobrenim sredstvima, a na iznose korištene u obliku kredita korisnik plaća kamatu*. (Mikić, Orsag, Pološki Vokić, Sunajko, Švaljek 2011: 819).

[69] Pratećim je pravilnikom jasno definirano *da se pod pojmom investicija, u smislu ovoga Pravilnika, podrazumijevaju rashodi za nabavu nefinancijske imovine (osim prijevoznog sredstva u cestovnom prometu - osobnog automobila) koje općina, grad ili županija financira iz svoga proračuna* (Pravilnik o postupku zaduživanja te davanja jamstava i suglasnosti jedinica lokalne i područne (regionalne) samouprave (Narodne novine 55/2009, 139/2010).

investicije ako se ona financira kreditnim sredstvima) gradovi bi trebali financijski manje zahtjevne projekte financirati zaduživanjem na što kraći rok.

Kapitalni projekti (komunalna i cestovna infrastruktura, škole, sportske dvorane i sl.) uobičajeno se financiraju kreditnim sredstvima jer ih lokalne jedinice koriste u nedostatku vlastitih proračunskih prihoda. *Lokalne jedinice sa stabilnim fiskalnim kapacitetima (uglavnom veći gradovi) osim kreditima kod banaka, zadužuju se i izdavanjem lokalnih (municipalnih) obveznica* (Bajo, Jurlina Alibegović 2008: 147). Obveznice su prenosivi, dugoročni dužnički vrijednosni papiri, a izdavatelji obveznica na taj se način direktno zadužuju na financijskom tržištu. Obveznice može izdati država, financijske institucije, korporacije i lokalne jedinice. Obveznice koje izdaju lokalne jedinice (općine, gradovi i županije) nazivaju se municipalnim obveznicama. Obveznice su investitorima privlačne jer prema Novaku (2005: 241) *obećavaju investitorima povrat nominalne vrijednosti do dospijeća i plaćanje kamata u navedenim intervalima do dospijeća*. Konzervativnim su investitorima osobito privlačne municipalne obveznice jer, kako se napominje i*maju niži stupanj rizičnosti ulaganja zato što, osim vlastitih proračunskih prihoda, za njihove obveze dodatno jamči središnja država* (Bajo, Jurlina Alibegović 2008: 148). Naravno, zbog činjenice da država u konačnici jamči povrat sredstava, nužno je kao i kod dugoročnih kredita pribaviti suglasnost Vlade Republike Hrvatske za zaduženje.

Investicijski i mirovinski fondovi, zbog diverzifikacije svojih ulaganja, u potrazi za manje rizičnim dijelom svog portfelja ulažu sredstva u municipalne obveznice i obično ih *drže* do dospijeća iz razloga što se ovim tipom obveznica vrlo rijetko trguje na sekundarnom tržištu[70].

Sredinom devedesetih godina prošlog stoljeća municipalne obveznice pojavljuju se i na hrvatskom tržištu kapitala s prvim emisijama Istarske županije, a do 2015. godine obveznice su izdali i mnogi gradovi kao što su: Opatija, Koprivnica, Zadar, Rijeka, Split, Vinkovci i Osijek[71]. U tablici 14. nalaze se zadnje aktivne obveznice na Zagrebačkoj burzi, te je evidentno da je dolaskom gospodarske krize, a kasnije i značajnim padom cijene kapitala, opao interes lokalnih jedinica za izdavanjem obveznica.

[70] *Sekundarno je tržište financijsko tržište na kojem se prethodno izdani vrijednosni papiri mogu preprodavati (primjerice burze, devizna tržišta, terminska tržišta te tržišta opcija)* (Mishkin 2010: 26).
[71] Zanimljivo je primijetiti da Grad Zagreb nije izdao obveznice već se odlučio dati jamstvo na izdanje 300 milijuna EUR vrijednih obveznica Zagrebačkog holdinga 2007. godine.

Tablica 14. Pregled municipalnih obveznica na Zagrebačkoj burzi

Simbol	Izdavatelj	Broj izdanih	Nominala	Datum uvrštenja	Prestanak uvrštenja
GDRI-O-167A	Grad Rijeka	24.574.513	1,00 EUR	19. 7. 2006.	18. 7. 2016.
GRVI-O-17AA	Grad Vinkovci	42.000.000	1,00 HRK	25. 10. 2007.	18. 10. 2017.
GROS-O-17AA	Grad Osijek	25.000.000	1,00 HRK	5. 11. 2007.	26. 10. 2017.
GDST-O-15BA	Grad Split	8.100.000	1,00 EUR	31. 12. 2007.	25. 11. 2015.
GDST-O-177A	Grad Split	8.200.000	1,00 EUR	8. 8. 2008.	6. 7. 2017.

Izvor: Prikaz autora na temelju podataka Zagrebačke burze d.d. na dan 2. siječnja 2015. godine[72]

Uz kreditne poslove, upravljanje likvidnosti moguće je i korištenjem *faktoringa* jer *faktoring* jest pravni posao u kojemu pružatelj usluge *faktoringa*, na temelju i u skladu s ugovorom o *faktoringu* sklopljenim s dobavljačem i/ili kupcem, kupuje predmete *faktoringa* s pravom ili bez prava na regres (Zakon o faktoringu, čl. 4.). Stoga lokalne jedinice prodaju svoja potraživanja prije ugovorenog dospijeća temeljem ugovora s pružateljem usluge *faktoringa*[73] i odmah dobiju sredstva umanjena za kamate i naknade. Ovaj oblik *faktoringa* najčešće koriste gradovi, ali postoje i druge vrste definirane zakonom pa tako s obzirom na svoja obilježja, *faktoring* može biti:

1. *tuzemni - svi su subjekti rezidenti u smislu zakona kojim se uređuje devizno poslovanje*
2. *inozemni - u kojemu je najmanje jedan od subjekata nerezident*[74] *u smislu zakona kojim se uređuje devizno poslovanje*
3. *regresni - posao faktoringa u kojemu dobavljač jamči pružatelju usluga faktoringa za obvezu kupca*
4. *bezregresni – faktoring u kojemu cjelokupni rizik naplate tereti pružatelja usluge faktoringa, a dobavljač ne odgovara za naplativost predmeta faktoringa*
5. *dobavljački (obrnuti) faktoring* (Zakona o faktoringu, čl. 8.).

[72] https://zse.hr/hr/cijene-vrijednosnih-papira/36?date=2015-01-02&model=ALL&type=MUNI-BOND (pristupljeno: 8. studenoga 2020.).

[73] U Hrvatskoj djeluju četiri *faktoring* društva koja su temeljem Zakona o *faktoringu* pod regulacijom Hrvatske agencije za nadzor financijskih usluga. https://www.hanfa.hr/leasing-i-faktoring/registri/faktoring-drustva/ (pristupljeno: 31. listopada 2020.).

[74] *U skladu s odredbama Zakona o porezu na dobit nerezident je pravna osoba kojoj sjedište nije upisano u sudski ili drugi registar ili upisnik u Republici Hrvatskoj i kojoj je mjesto stvarne uprave i nadzor poslovanja izvan Republike Hrvatske. Nerezident je i poduzetnik fizička osoba s prebivalištem ili uobičajenim boravištem izvan Republike Hrvatske koji nema u Republici Hrvatskoj upisanu djelatnost u registar ili upisnik. Prema Zakonu o porezu na dohodak nerezident je fizička osoba koja u Republici Hrvatskoj nema ni prebivalište ni uobičajeno boravište, a u njoj ostvaruje dohodak što se oporezuje u skladu s tim zakonom* (Porezna uprava). https://www.porezna-uprava.hr/baza_znanja/Stranice/Nerezident.aspx (pristupljeno: 9. prosinca 2020.).

Dobavljački (obrnuti) *faktoring* posebna je vrsta *faktoringa u kojemu pružatelj usluge faktoringa i kupac ugovaraju program plaćanja kupčevih dugova dobavljačima na način da se pružatelj usluge faktoringa obvezuje plaćati tražbine koje kupčevi dobavljači imaju prema kupcu prije dospijeća ili o dospijeću predmeta faktoringa na zahtjev dobavljača ili po uputi kupca, uz prijenos tako isplaćenih predmeta faktoringa s dobavljača na pružatelja usluge faktoringa* (Zakona o *faktoringu* čl. 11.). Na slici br. 7 dan je grafički prikaz dobavljačkog *faktoringa* gdje grad predstavlja kupca-dužnika.

Slika 7. Dobavljački *faktoring*

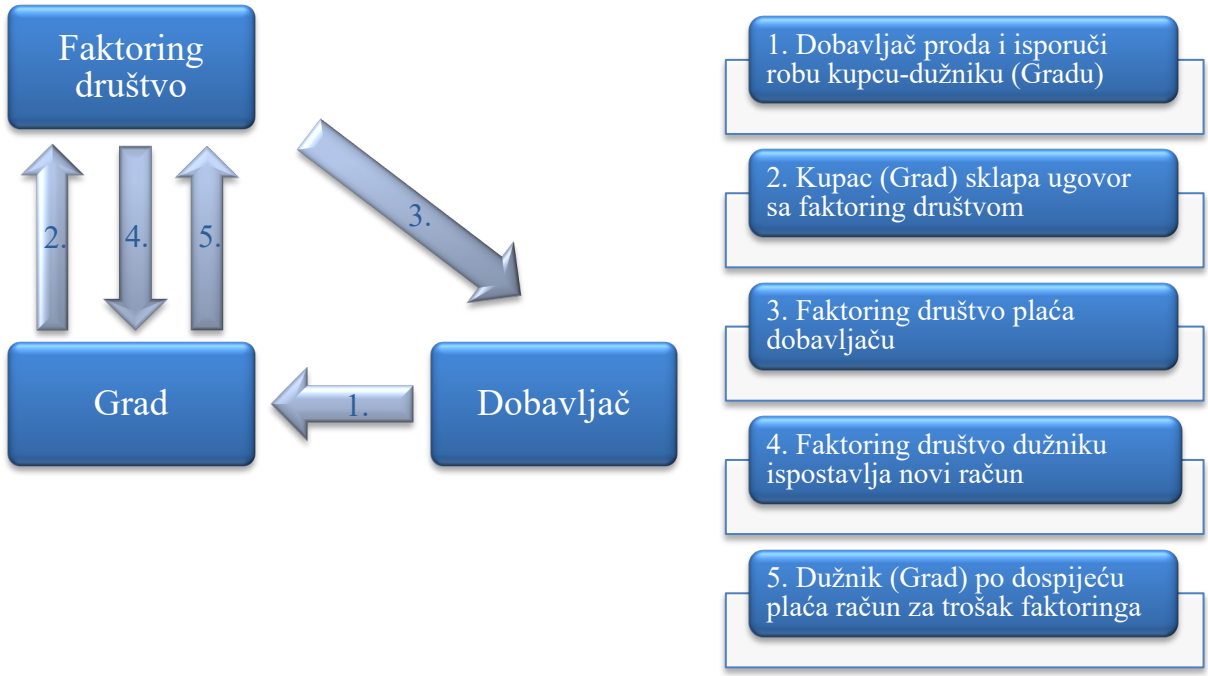

Izvor: Krmpotić (2015) na temelju Zakona o *faktoringu*[75]

Kod dobavljačkog *faktoringa* lokalna jedinica, temeljem primljenih faktura, ugovara svojevrstan kredit s *faktoring* društvom i oni ispunjavaju obvezu lokalne jedinice prema trećim osobama. Lokalna jedinica za to plaća naknadu i kamatu, a obveza plaćanja joj se prolongira za 60 do 180 dana. Ovakvi se ugovori brzo realiziraju (brže nego klasični krediti), a velika mu je prednost i činjenica da ne ulaze u kreditnu zaduženost jer je samo riječ o načinu upravljanja likvidnosti. Financijski *leasing* dodatni je oblik zaduživanja koji koriste gradovi. Riječ je o pravnom poslu *u kojem davatelj leasinga pribavlja objekt leasinga na način da od dobavljača objekta leasinga kupnjom stekne pravo vlasništva na objektu leasinga, te primatelju leasinga odobrava korištenje tog objekta leasinga kroz određeno vrijeme, a primatelj leasinga se*

[75] Narodne novine br. 94/2014, 85/2015, 41/2016

obvezuje za to plaćati naknadu (Zakon o leasingu, članak 4.). Zakon o *leasingu* u sljedećem članku definira i osnovne vrste *leasinga* koji s*e s obzirom na sadržaj i obilježja posla dijele na financijski i operativni*. Kod financijskog *leasinga* primatelj *leasinga* snosi i troškove amortizacije, a postoji i mogućnost stjecanja vlasništva nad objektom *leasinga*. U kreditnu zaduženost ulazi samo *leasing* opreme i građevina, te je u tim slučajevima potrebna i suglasnost Ministarstva financija. Za razliku od financijskog *leasinga*, kod operativnog se *leasinga* plaća naknada, nema mogućnosti stjecanja vlasništva te ga se samim time ne uključuje u zaduženost.

Jamstvo je instrument osiguranja kojim vjerovnik dodatno osigurava naplatu svog budućeg potraživanja te samim time to potraživanje postaje manje rizično i cjenovno povoljnije za osnovnog dužnika. *Jamstvo može izdati i država te njime Republika Hrvatska jamči ispunjenje obveza za koje se daje jamstvo* (Zakon o proračunu, članak 3.), a analogno tomu jamstvo može izdati i lokalna jedinica te je onda to instrument osiguranja kojim lokalna jedinica jamči za ispunjenje obveze svoje ustanova ili trgovačkog društva[76] (npr. kada komunalno društvo gradi infrastrukturu ili nabavlja opremu) i ta se jamstva uključuju u zaduženost lokalne jedinice. *Odluku o davanju jamstva donosi predstavničko tijelo lokalne jedinice, razmjerno njezinu udjelu u vlasništvu, a većinski vlasnik, odnosno osnivač, obvezan je prije davanja jamstva ishoditi suglasnost ministra financija* (Zakon o proračunu). Često se u praksi dogodi da komunalne tvrtke koje su u vlasništvu više lokalnih jedinica[77], jamstvo zatraže samo od najveće lokalne jedinice, a osobito ako je investicija isključivo vezana za područje te lokalne jedinice (Krmpotić 2015).

Također, sukladno zakonu *jedinica područne (regionalne) samouprave može dati jamstvo jedinici lokalne samouprave na svojem području uz suglasnost Vlade, a dano se jamstvo uključuje u opseg mogućeg zaduživanja jedinice područne (regionalne) samouprave* (Zakon o proračunu čl. 91.). Kada tvrtke ili ustanove, kojima je dano jamstvo, ne plate kredit na vrijeme, plaćanje obveze vrši se iz proračuna gradova koji su dali jamstvo, a nakon toga uspostavlja se *potraživanje od glavnog dužnika umjesto kojega je bila plaćena obveza te je gradonačelnik obvezan pokrenuti postupak za naplatu regresnog zahtjeva na osnovi ugovora o osiguravanju potraživanja* (Zakon o proračunu, čl. 66.).

[76] Zanimljivo je istaknuti da je u listopadu 2012. *Agencija za zaštitu tržišnog natjecanja odobrila državnu potporu za sanaciju sadržanu u jamstvu koje je Grad Split dao nogometnom klubu Hajduk za kreditno zaduženje kod dvije banke, u ukupnom iznosu od 30 milijuna kuna* (AZTN).

[77] Dobar su primjer društva koja se bave vodnim uslugama, pa tako recimo Vodovod-Osijek d. o. o. u vlasničkoj strukturi osim Grada Osijeka (78,29 % vlasništva) ima i okolne općine: Antunovac, Čepin, Erdut, Ernestinovo, Vuka, Semeljci i Vladislavci.

Gradovi obično izbjegavaju regresne zahtjeve te najčešće pretvaraju svoja potraživanja u udio u kapitalu jer u zakonu također stoji d*a na prijedlog načelnika, gradonačelnika ili župana, predstavničko tijelo odlučuje o stjecanju udjela lokalnih jedinica u kapitalu trgovačkih društava te se na taj način i dodatno osnažuje navedeno društvo* (Zakon o proračunu, čl. 67.). Ponekad i gradovi unaprijed (prilikom izrade proračuna) sa svojim trgovačkim društvima dogovaraju plaćanja po jamstvima odnosno u proračunu budu jasno naznačene pozicije kapitalne pomoći trgovačkim društvima u javnom sektoru s kojih se onda i vrše ova plaćanja.
Sukladno članku 87. Zakona o proračunu, Vlada Republike Hrvatske, a na prijedlog ministra financija *daje suglasnost na dugoročno zaduživanje lokalnih jedinica*[78], nadalje Vlada Republike Hrvatske *može dati suglasnosti za zaduživanje jedinicama lokalne i područne (regionalne) samouprave, najviše do 3 % ukupno ostvarenih prihoda poslovanja svih jedinica lokalne i područne (regionalne) samouprave*[79] *iskazanih u financijskom izvještaju o prihodima i rashodima, primitcima i izdatcima za razdoblje od 1. siječnja do 31. prosinca 2019. godine* (Zakon o izvršavanju Državnog proračuna Republike Hrvatske za 2020. godinu čl. 22.).
Također, istim su člankom zakona definirani i izuzetci od navedenog pravila, odnosno to se *ne odnosi na:*

1. *jedinice lokalne i područne (regionalne) samouprave kojima je Vlada Republike Hrvatske dala suglasnosti do 31. prosinca 2019., a nisu korištene u 2019. godini*
2. *jedinice lokalne samouprave na potpomognutim područjima*
3. *jedinice lokalne i područne (regionalne) samouprave koje se zadužuju za projekte koji se sufinanciraju iz sredstava Europske unije do iznosa prihvatljivih troškova*
4. *projekte unapređenja energetske učinkovitosti u kojima sudjeluju jedinice lokalne i područne (regionalne) samouprave* (Zakon o izvršavanju Državnog proračuna Republike Hrvatske za 2020. godinu).

Pravna osoba u većinskom vlasništvu ili suvlasništvu jedinice lokalne i područne (regionalne) samouprave i ustanova čiji je osnivač jedinica lokalne i područne (regionalne) samouprave može dugoročno zaduživati samo za investiciju uz suglasnost većinskog vlasnika, odnosno osnivača (Zakon o proračunu, čl. 90.).

[78] Istim je člankom Zakona definirano da o *zahtjevu za davanje suglasnosti za zaduživanje Vlada odlučuje u roku od 40 dana nakon podnošenja potpunog zahtjeva*.
[79] Prema podatcima Ministarstva financija, ukupni su prihodi poslovanja u 2018. godini iznosili 26,4 milijarde kuna, te je sukladno tome limit od 3 % trebao biti na razini od 790,4 milijuna kuna u 2019. godini. https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

U opseg mogućeg zaduživanja lokalne samouprave ulaze:

1. *zaduživanje pravnih osoba u većinskom vlasništvu ili suvlasništvu jedinice lokalne i područne (regionalne) samouprave koje su u godišnjim financijskim izvješćima za godinu koja prethodi godini u kojoj se zadužuju iskazale gubitak*
2. *zaduživanje pravnih osoba u većinskom vlasništvu ili suvlasništvu jedinice lokalne i područne (regionalne) samouprave koje se zadužuju u razdoblju od dvije godine od dana upisa osnivanja u sudski registar*
3. *zaduživanje ustanova čiji je osnivač jedinica lokalne i područne (regionalne) samouprave* (Zakon o proračunu).

Ukoliko komunalna društva posluju pozitivno u kontinuitetu, dana suglasnost neće smanjiti opseg mogućeg zaduživanja lokalne jedinice, a ukoliko se to tijekom otplate promijeni (društvo ostvari negativan rezultat) nadležna lokalna jedinica dužna je obuhvatiti taj dug po izdanoj suglasnosti u opseg zaduženja. *Ako statutom ili odlukom jedinice lokalne i područne (regionalne) samouprave nije propisano tko odlučuje o gore nabrojanim suglasnostima, odluku donosi predstavničko tijelo jedinice lokalne i područne (regionalne) samouprave, razmjerno njezinu udjelu u vlasništvu* (Zakon o proračunu). Zakonom su obuhvaćeni i *izvanproračunski korisnici proračuna jedinica lokalne i područne (regionalne) samouprave te za njih isti zakon kaže da se mogu zaduživati i davati jamstva samo za investicije uz suglasnost jedinice lokalne i područne (regionalne) samouprave, a zaduživanje i dano jamstvo uz danu suglasnost uključuje se u opseg mogućeg zaduživanja jedinice lokalne i područne (regionalne) samouprave* (Zakona o proračunu, čl. 94.), a jedinice su dužne prije davanja suglasnosti ishoditi suglasnost ministra financija.

3.3.2. Rizici zaduživanja

Zaduživanje, ali i sam proces otplate kreditnog duga povezan je s određenim rizicima. Iako su predstavnici javnog sustava u pravilu dobrog boniteta te su rizici nemogućnosti otplate kredita vrlo nisi, svejedno se određeni rizici moraju uračunati i uzeti u obzir, a Bajo i Jurlina Alibegović (2008: 169) navode sljedeće *osnovne rizike zaduživanja:*

1. *promjena poreznih prihoda*
2. *kamatna stopa*
3. *valutni rizik*
4. *rizik likvidnosti*
5. *ostali rizici zaduživanja*.

Rizik promjene poreznih prihoda najveći je rizika koji može utjecati na poslovanje lokalne jedinice. Iako porezni prihodi ovise o velikom broju čimbenika, najveći direktni utjecaj, te i najveći potencijalni rizik, na njihovu promjenu imaju zakonske izmjene i izmjene odluka lokalnih jedinica. Primjerice Krmpotić (2015), navodi da je izmjenama i dopunama Zakona o porezu na dohodak donesenim krajem 2014. godine, Sabor Republike Hrvatske usvojio, na prijedlog Vlade Republike Hrvatske, povećanje osobnog odbitka te izmjenu poreznih razreda čime su direktno smanjeni porezni prihodi lokalnih jedinica i središnje države. Prilikom donošenja ovih zakonskih izmjena Vlada Republike Hrvatske procijenila je da će se neto plaće 1,2 milijuna građana zbog toga povećati, ali i da će se prikupiti 1,8 milijardi kuna manje prihoda od poreza na dohodak te prireza porezu na dohodak svake godine. Na taj se način direktno smanjio dugoročni otplatni potencijal lokalnih jedinica jer su se porezni prihodi pojedinih lokalnih jedinica smanjili i preko 10 %. Neke su lokalne jedinice nakon toga uvele ili povećale postojeće stope prireza i na taj način djelomično *kompenzirale* smanjenje prihoda. Također, rizik promjene poreznih prihoda očituje se i kroz aktivnosti lokalnih jedinica u pogledu naplate vlastitih prihoda. Naime, neaktivnost po pitanju, primjerice prisilne naplate, može značajno smanjiti iznos prikupljenih poreza.

Rizik promjene kamatnih stopa kredita također ulazi u značajne rizike kod otplate ugovorenih kredita. Naime, banke želeći sebe zaštititi nude kredite s varijabilnom kamatnom stopom, čija se kamata računa putem sume neke referentne kamatne stope i kamatne marže. Najčešće se za referentnu kamatnu stopu koristi EURIBOR (rjeđe LIBOR ili ZIBOR) ili NRS (nacionalna referentna stopa HNB-a), uvećan za fiksni dio kamatne marže. Bajo i Jurlina Alibegović (2008: 169) ističu *da promjene uvjeta na financijskim tržištima izravno utječu i na promjene iznosa kamate duga lokalne jedinice*. Kako lokalne jedinice nemaju utjecaj na kretanja na novčanim tržištima i tržištu kapitala, a kako bi se adekvatno zaštitili od rizika negativne promjene kamatnih stopa, zadnjih se godina najčešće ugovaraju krediti s fiksnom kamatnom stopom.

Valutni rizik definira se kao *rizik da će neka valuta imati manju (ili veću) vrijednost na tržištu u budućnosti* (Rocco 1993: 493). Andrijašević i Račić Žalibar koristeći usko vezani termin tečajni rizik, definiraju valutni rizik *kao neizvjesnost vrijednosti domaće valute u odnosu na vrijednost strane valute zbog promjene deviznog tečaja. Naime, pod utjecajem brojnih ekonomsko-političkih čimbenika i neprestanih promjena ponude i potražnje za devizama, devizni je tečaj podložan učestalim fluktuacijama, koje dovode do odstupanja stvarne vrijednosti jedne (ugovorene) valute i druge valute, tj. one u kojoj se mora izvršiti plaćanje* (Andrijašević, Račić Žalibar 1997).

Valutni je rizik prisutan kod lokalnih jedinica u Republici Hrvatskoj jer su njihovi prihodi u kunama, a kreditne obveze su najviše vezane za euro ili švicarske franke (uglavnom putem valutne klauzule). Ta valutna neusklađenost može dovesti u opasnost mogućnost otplate kreditnih obveza jer se porastom tečaja povećava i iznos plaćanja u kunama (Krmpotić 2015). Primjerice, u tablici 15. prikazano je kretanje tečaja švicarskog franka tijekom druge polovine mjeseca siječnja 2015. godine.

Tablica 15. Nominalni dnevni tečaj kune prema švicarskom franku od 15. do 24. siječnja 2015. godine (srednji tečaj HNB-a)

U HRK	15.1.15.	16.1.15.	17.1.15.	18.1.15.	19.1.15.	20.1.15.	21.1.15.	22.1.15.	23.1.15.	24.1.15.
HRK/CHF	6,393	7,398	7,538	7,538	7,538	7,661	7,571	7,704	7,720	7,859
% Promjena		**15,72%**	**17,91%**	**17,91%**	**17,91%**	**19,82%**	**18,41%**	**20,50%**	**20,75%**	**22,92%**

Izvor: Izračun autora na temelju podataka Hrvatske narodne banke (HNB).[80]

U prikazanoj tablici dolazi do snažnog slabljenja kune u odnosu na švicarski franak, a vrhunac je bio 24. siječnja kada je kuna gotovo 23 % slabija odnosno potrebno je izdvojiti 23 % više kuna za otplatu jednakog duga u švicarskim francima. Ugovaranjem terminskog tečaja ili ugovaranje kunskih kredita (koji su posljednjih godina cjenovno konkurentni kreditima s valutnom klauzulom) predstavlja adekvatnu zaštitu od ove vrste rizika.

Prilikom izvršavanja proračuna može doći do raznih negativnih kretanja koji mogu narušiti likvidnost lokalnih jedinica. Ovu vrstu rizika moguće je prevenirati dobrim upravljanjem gotovinom ili korištenjem financijskih instrumenata kao što je kratkoročni kredit ili *faktoring*.

Uz već navedene rizike, prema Baji i Jurlini Alibegović (2008: 170), postoji i nekoliko manjih oblika rizika zaduživanja lokalnih jedinica (i njihovih korisnika), a to su: politički rizik, rizik poslovne konkurencije, operativni rizik i viša sila. Politički rizik govori o odnosu lokalnih jedinica s regionalnim jedinicama i sa središnjom vlasti, a najčešće se očituje kroz česte zakonske izmjene (primjerice promjene poreznih zakona, tretmana vlasništva i sl.). Rizik poslovne konkurencije indirektno je vezan za lokalne jedinice, jer loši financijski rezultati trgovačkih društava koja sudjeluju u tržišnom natjecanju mogu posljedično utjecati na veća izdvajanja iz proračuna lokalne jedinice (veće subvencije i sl.).

[80] https://www.hnb.hr/temeljne-funkcije/monetarna-politika/tecajna-lista/tecajna-lista (pristupljeno: 14. studenoga 2020.).

Operativni rizik vezan je za interno funkcioniranje i poslovanje lokalne jedinice, odnosno u Ekonomskom leksikonu (2011: 617) definiran je kao s*kup rizika koji se ne mogu svrstati u financijske rizike, a uključuju rizik ljudske pogreške, tehnološki rizik, proceduralni rizik, prodajni rizik i rizik okruženja*. Uz njega se javlja i vrsta rizika koja se naziva viša sila. Naime, prema Baji i Jurlini Alibegović (2008: 170) *viša sila podrazumijeva događaje koji negativno utječu na poslovanje dužnika, kao što su epidemije, rat, terorističko djelovanje, elementarne nepogode, te štrajkovi i ostalo što je vrlo teško ili gotovo nepredvidivo predvidjeti kao vrstu rizika, a pripada u domenu kriznog upravljanja financijama*.

3.3.3. Instrumenti osiguranja kod zaduživanja

Prilikom zaduživanja poduzeća koriste različite vrste osiguranja povrata kredita kako bi dobili povoljniju kamatu ili kako bi uopće dobili priliku za zaduživanje. Odgovarajući budući novčani tijek osnova je svake kreditne analize, ali zbog rizika koji su prisutni u poslovanju svakog poduzetnika, kreditori se često oslanjaju na veći broj različitih vrsta instrumenata osiguranja, a kod rizičnijih plasmana u pravilu traže da uz mogućnost naplate na novčanim sredstvima poduzetnika, dodatni instrument osiguranja bude zalog na nekretnini. Kod zaduživanja gradova slična je situacija te se najčešće koriste:

1. mjenica/zadužnica
2. jamstvo
3. hipoteka.

Gradovi prilikom zaduživanja, u pravilu, koriste bankovne kredite te zauzvrat daju samo mjenice i zadužnice, odnosno kreditori obično smatraju da je dostatno osiguranje putem eventualne prisilne naplate na novčanim sredstvima. Veliki infrastrukturni projekti državnih poduzeća kao što su Hrvatske ceste d. o. o., Hrvatske autoceste d. o. o. i HŽ Infrastruktura d. o. o.[81] osiguravaju se državnim jamstvom Republike Hrvatske, a puno rjeđe taj instrument koriste i gradovi (primjerice Grad Vrbovec[82] je dobio državno jamstvo). Također, gradovi kod velikih kreditnih zaduženja svojih poduzeća i ustanova izdaju jamstva kako bi adekvatno osigurali povrat takvih kredita. Dodatno, kako su gradovi vlasnici imovine velike vrijednosti, nerijetko kao osiguranje povrata kredita nude hipoteke na svoju imovinu, a opet sve s ciljem ugovaranja

[81] https://mfin.gov.hr/istaknute-teme/javni-dug/drzavna-jamstva/197 (pristupljeno: 17. svibnja 2020.).
[82] Jamstvo je izdano 22. siječnja 2018. godine u korist Zagrebačke banke za refinanciranje obveza u iznosu 10,8 milijuna kuna i rokom dospijeća 2029. godina.

maksimalno povoljnih kreditnih uvjeta. Kod izdavanja municipalnih obveznica situacija je nešto drugačija, jer se u pravilu radi o neosiguranoj obvezi gradova.

3.3.4. Proces i aktivnosti zaduživanja na primjeru gradova

Zakon o proračunu detaljno je i sustavno regulirao proces zaduživanja gradova. Dvije su bitne pretpostavke u tom procesu. Gradovi prvo moraju moći financijski podnijeti otplatu budućeg zaduženja, a nakon toga moraju i poštovati složenu zakonsku proceduru. Navedena se procedura razlikuje ovisno o tome radi li se o direktnom zaduživanju lokalnih jedinica ili o posrednom zaduživanju (ukoliko se zadužuju tvrtke koje su u vlasništvu lokalnih jedinica ili njihove ustanove). Naravno *ključna pretpostavka za zaduživanjem je stabilan fiskalni kapacitet lokalnih jedinica te njihova sposobnost da budućim prihodima jamče povrat glavnice i kamata* (Bajo 2004). Zakon o proračunu definira koje su granice zaduživanja, a svrha mu je, prema Krmpotiću (2015), osigurati redovitu otplatu svih preuzetih kreditnih obveza te onemogućiti lokalnim jedinicama da, zbog previsokog kreditnog zaduženja, izgube mogućnost pravovremenog plaćanja obveza i financiranja svih funkcija nužnih za stanovnike. Stoga je zakonom definirano *da ukupna godišnja obveza jedinice lokalne i područne (regionalne) samouprave može iznositi najviše do 20 % ostvarenih prihoda u godini koja prethodi godini u kojoj se zadužuje* (Zakon o proračunu, čl. 88.). To se grafički prikazuje u obliku koeficijenta zaduženosti i glasi:

$$Koeficijent\ zaduženosti\ lokalnih\ jedinica = \frac{Ukupna\ godišnja\ obveza\ JLP(R)S}{Ostvareni\ prihodi\ u\ prethodnoj\ godini}$$

U iznos ukupne godišnje obveze uključuje se iznos:

1. *prosječnog godišnjeg anuiteta*[83] *po kreditima i zajmovima*
2. *obveze na osnovi izdanih vrijednosnih papira*
3. *obveze na osnovi danih jamstava i suglasnosti*
4. *dospjele nepodmirene obveze iz prethodnih godina* (Zakon o proračunu).

Prilikom izračuna koeficijenta zaduženosti polazišnu osnovu čine iznosi budućih otplata kredita koji se procjenjuju temeljem otplatnih planova. Tome se onda dodaju buduće obveze za izdane

[83] *Anuitet je izraz kojim se označuju periodične otplate dugova. Sadrži dio nominalne vrijednosti duga i dio kamata. Anuiteti za otplatu dugova mogu biti jednaki godišnji ili polugodišnji iznosi, zatim anuiteti s jednakim otplatnim kvotama ili varijabilni anuiteti. Anuitetom se označuju i jednaki periodični (godišnji, odnosno polugodišnji) novčani iznosi, odnosno jednaki novčani tokovi* (Mikić, Orsag, Pološki Vokić, Sunajko i Švaljek 2011: 25).

vrijednosne papire. Za anuitetne obveznice[84] *utvrđuju se u iznosu godišnjeg anuiteta, a za obveznice kod kojih se amortizira glavnica o dospijeću utvrđuju se za pretpostavljeno dospijeće pripadajućega godišnjeg dijela glavnice i pripadajućih kamata* (Zakon o proračunu). Kao treća komponenta u izračun koeficijenta zaduženosti ulaze i obveze na osnovu danih jamstava i suglasnosti (samo one koje ulaze u opseg zaduživanje), a kao posljednju komponentu u izračun je neophodno uključiti i dospjele nepodmirene obveze iz prethodnih godina. Zakon definira *da u poslovnim transakcijama između poduzetnika i osoba javnog prava*[85] *u kojima je osoba javnog prava dužnik novčane obveze, može se ugovoriti rok ispunjenja novčane obveze do 30 dana (samo se iznimno taj rok može produljiti na 60 dana)* (Zakon o financijskom poslovanju i predstečajnoj nagodbi čl. 12.).

Lokalne jedinice bi u zakonskim rokovima trebale ispunjavati svoje preuzete obveze, a kako to ne čine, te obveze im smanjuju mogućnost zaduživanja. Uobičajeno je da iznos nepodmirenih obveza iz prethodne godine bude najveći početkom tekuće godine, stoga lokalne jedinice ponekad vrlo pažljivo biraju trenutak kada će podnijeti zahtjev za dugoročnim zaduženjem prema resornom ministarstvu i izvršiti izračun koeficijenta zaduženosti (Krmpotić 2015). Izračun koeficijenta se osim kod zaduživanja koristi i prilikom planiranja i pripreme budućeg proračuna. Suma ostvarenih proračunskih prihoda pojedine jedinice lokalne i područne (regionalne) samouprave[86] umanjuje se, prilikom izračuna nazivnika navedene formule za izračun koeficijenta zaduženosti z*a prihode:*

1. *od domaće i strane pomoći i donacija*
2. *iz posebnih ugovora: sufinanciranje građana za mjesnu samoupravu*[87]
3. *ostvarene s osnove dodatnih udjela u porezu na dohodak i pomoć izravnanja za financiranje decentraliziranih funkcija* (Zakon o proračunu).

[84] *Anuitetska obveznica, obveznica sa serijskom amortizacijom koja se amortizira u jednakim (godišnjim, a češće polugodišnjim) anuitetima. Izdaje se znatno rjeđe od kuponske, odnosno jednokratne obveznice. Anuiteti obveznica sadrže dio nominalne vrijednosti emitirane obveznice i pripadajuće kamate* (Mikić, Orsag, Pološki Vokić, Sunajko i Švaljek 2011: 25).

[85] *Osobe javnog prava jesu javni naručitelji kako su uređeni propisima o javnoj nabavi i sektorski naručitelji kako su uređeni propisima o javnoj nabavi, osim trgovačkih društava koja odgovaraju definiciji poduzetnika* (Zakon o financijskom poslovanju i predstečajnoj nagodbi. Narodne novine br. 108/2012, 144/2012, 81/2013, 112/2013, 78/2015 i 71/2015).

[86] Navedeni prihodi prema ekonomskoj klasifikaciji su: a) *prihodi od poreza; b) doprinosi za obvezna osiguranja; c) pomoći; d) prihodi od imovine; e) prihodi od pristojbi i naknada; f) ostali prihodi i g) prihodi od prodaje nefinancijske imovine* (Zakon o proračunu).

[87] Sufinanciranje građana za mjesnu samoupravu predstavlja, u praksi, sredstva koja građani izdvajaju temeljem posebnih propisa. Primjerice u cijeni sakupljanja i odvoza komunalnog otpada u Gradu Osijeku sadržan je dio sredstava koji se usmjeravaju prema sanaciji odlagališta i izgradnji reciklažnih dvorišta (sukladno trenutno važećim zakonskim propisima).

Prihodi su, dakle, za potrebe izračuna koeficijenta zaduženosti prilagođeni na način da se isključe prihodi koji nisu namijenjeni otplatama stvorenih kreditnih obveza.

Ukoliko lokalne jedinice koriste kreditna sredstva kako bi sufinancirali projekte iz nacionalnih i EU fondova te projekte iz područja energetske učinkovitosti, ti im krediti ne ulaze u spomenuta ograničenja odnosno korištenje tih kredita ne utječe na suglasnost Vlade Republike Hrvatske niti kasnija otplata utječe na koeficijent kreditne zaduženosti. Jedino što je nužno i dalje obavještavati Ministarstvo financija o statusu otplata tih kredita. Osim što ovo zakonsko rješenje evidentno potiče lokalne jedinice na realizaciju te vrste projekata, ono predstavlja i značajnu opasnost da će pojedine lokalne jedinice, bez jednakovrijednog nadzora i limita, u želji za ubrzanim razvojem infrastrukture (koja bi dijelom bila financirana sredstvima iz raznih fondova), dovesti u pitanje mogućnost buduće otplate postojećih, ali i za ovu namjenu uzetih kredita[88]. Te bi se lokalne jedinice mogle prekomjerno zadužiti, a kada krene otplata tih kredita mogle bi postati nelikvidne.

Sukladno propisima, svaka lokalna jedinica mora obratiti pažnju da joj koeficijent zaduženosti ne bude veći od 0,2 odnosno da joj vrijednosti budućih otplata ne prelaze 20 % njihovih *osnovnih* prihoda. Zakonske promjene mogu negativno utjecati na prihode lokalne jedinice i u kratkom razdoblju povećati navedeni koeficijent do te mjere da *probiju* zakonsku granicu i formalno postanu prezadužene. Također, sličan efekt imaju gospodarska kretanja, primjerice kriza uzrokovana virusom Covid-19.

Navedena je kriza smanjila prihode lokalnih jedinica, ali i povećala troškove u borbi za očuvanje radnih mjesta. Ukoliko se lokalne jedinice nađu u takvoj situaciji, gube mogućnost dugoročno se zadužiti, osim za ranija spomenuta izuzeća, sve do ponovnog smanjenja koeficijenta u zakonske granice. Postoje naravno i načini kako lokalne jedinice, u kratkom roku, mogu smanjiti navedeni koeficijent. Primjerice prijevremenom otplatom dijela zaduženja, produljenjem rokova otplate dijela kredita ili smanjenjem iznosa dospjelih nepodmirenih obveza.

Proces zaduživanja lokalnih jedinica vrlo je zahtjevan i složen, a započinje izglasavanjem proračuna putem kojeg se definiraju potrebe za dodatnim proračunskim izvorom. Proračunom se definira i namjena te dinamika korištenja kreditnih sredstava.

[88] Osobito vodeći računa o ranije navedenim rizicima kao što su dugoročno nesigurni porezni prihodi uslijed čestih promjena porezne politike ili pak trenutno povijesno niskim razinama EURIBOR-a.

Zakon o javnoj nabavi, u članku 30. definira da se *zajmovi i krediti izuzimaju iz postupaka javne nabave, stoga gradovi samostalno definiraju i provode postupke utvrđivanja najpovoljnijih kreditora, a sve nakon izglasavanja proračuna (ili donesenih izmjena i dopuna proračuna). Lokalna vlast, uz to, nema kontrolu nad uvjetima na tržištu novca pod kojima se mora zaduživati i najbolje što može je da pribavi sredstva po što povoljnijim uvjetima koji joj se u tom trenutku nude, pri čemu trošak ovisi o fiskalnom položaju i 'kreditnom statusu'* (Musgrave, Musgrave 1988: 602). Za neke je to odmah i poslovna banka s kojom imaju ugovor o poslovnom računu, a one transparentnije u pravilu objavljuju pozive bankama na svojim mrežnim stranicama i/ili šalju pozive za dostavu ponuda putem elektroničke pošte zainteresiranim financijskim institucijama.

Nakon provedenog postupka prikupljanja ponuda (ili pribavljene samo jedne ponude), slijedi odluka o odabiru najpovoljnije ponude koju donosi čelnik lokalne jedinice nakon što se uzmu u obzir svi troškovi kao što su:

1. interkalarne[89] i redovne kamate
2. naknade (za odobrenje kredita, za rezervaciju sredstava u korištenju i sl.)
3. ostali troškovi.

Zakon o proračunu u svom članku 87. kaže *da odluku mora potvrditi predstavničko tijelo uz suglasnost Vlade Republike Hrvatske i na prijedlog ministra financija* - te se stoga prvo predstavničkom tijelu dostavlja prijedlog odluke o dugoročnom zaduživanju (prema postignutim uvjetima) na razmatranje i donošenje. Nakon odluke predstavničkog tijela, cjelokupna se dokumentacija dostavlja u Ministarstvo financija koje provjerava dokumentaciju (primarno stupanj zaduženosti lokalne jedinice) te nakon toga podnosi prijedlog Vladi Republike Hrvatske. Navedeni je proces prikazan i grafički slikom br. 8.

[89] *Interkalarne kamate predstavljaju način naplate kamata u periodu korištenja kredita. Na svaki iskorišteni dio kredita obračunava se kamata od trenutka korištenja do početka otplate kredita* (Gorenc 1997: 132).

Slika 8. Proces zaduživanja lokalne jedinice vlasti

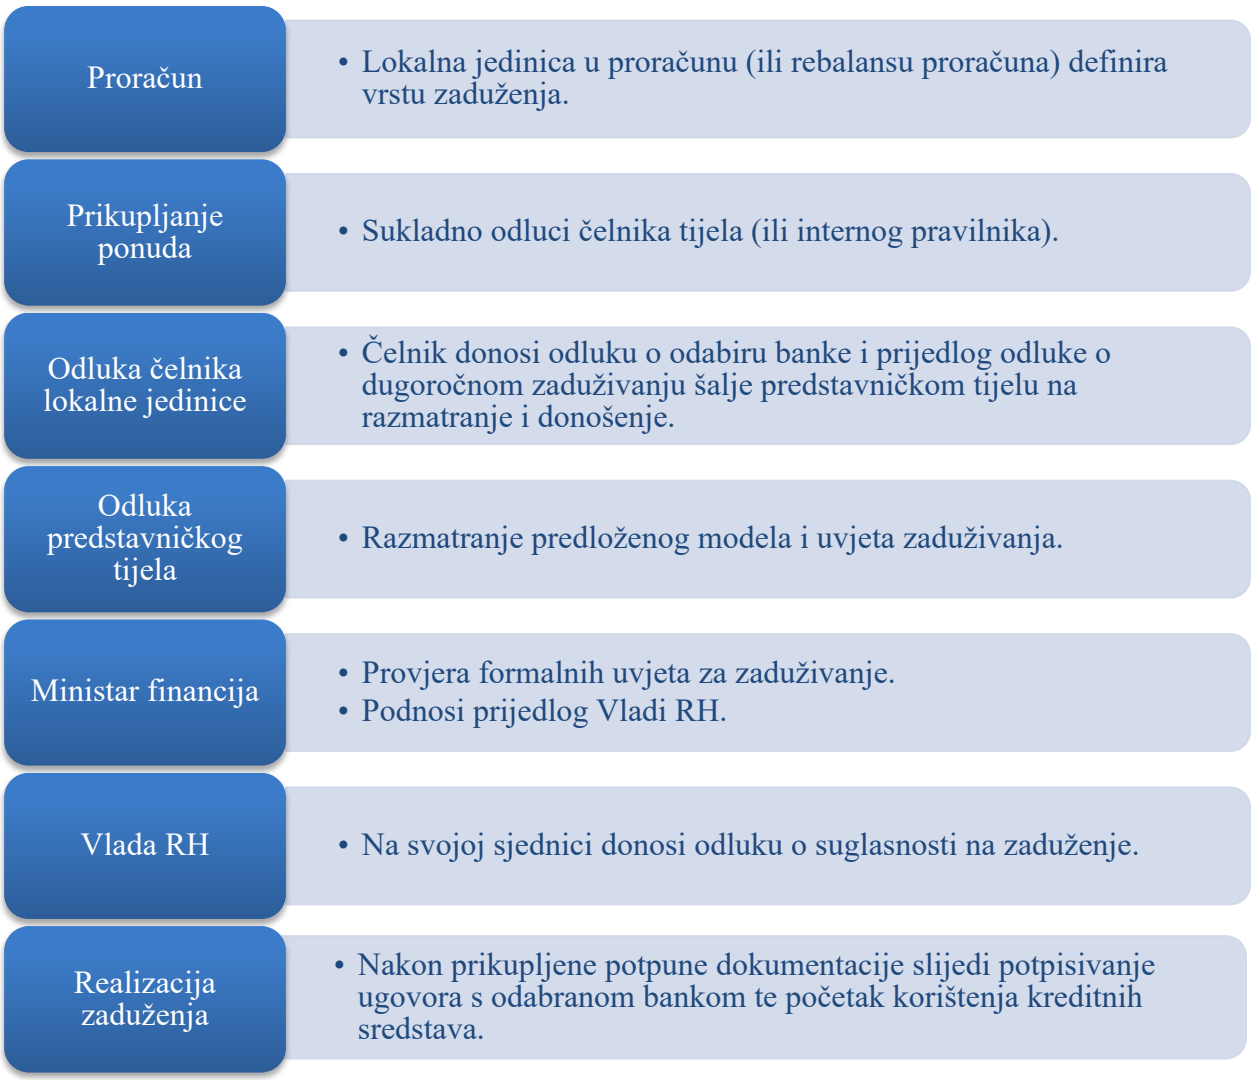

Izvor: Prikaz autora na temelju Zakona o proračunu

Vlada Republike Hrvatske u roku od 40 dana od dostave potpune dokumentacije donosi odluku o suglasnosti (članak 87. Zakona o proračunu). Nakon pozitivne odluke Vlade Republike Hrvatske[90], lokalna jedinica potpisuje ugovor s bankom koja je ponudila najbolje kreditne uvjete te potom započinje realizacija projekata iz predmetnog zaduženja.

[90] Vlada Republike Hrvatske je, primjerice, na svojoj 183. sjednici održanoj 10. listopada 2019. godine donijela Odluku o davanju suglasnosti Gradu Osijeku za zaduženje kod Zagrebačke banke d.d. Zagreb. U odluci se navodi da se daje suglasnost za zaduženje u iznosu od 10 milijuna kuna, s trajanjem otplate kredita od pet godina, uz fiksnu kamatnu stopu od 0,84 % godišnje i jednokratnu naknadu za trošak obrade zahtjeva u visini od 0,17 % odobrenog iznosa kredita te da će se sredstva koristiti za financiranje kapitalnog projekta *Industrijska zona Nemetin*.

Istim je člankom Zakona o proračunu definirano i da lokalna jedinica u roku od osam dana od sklapanja ugovora mora o tome izvijestiti Ministarstvo financija, ali i da mora izvještavati Ministarstvo financija svaka tri mjeseca o otplati kredita.

Ovaj proces ne odnosi se na kratkoročna zaduženja, te za tu vrstu zaduženja nije potrebna odluka Vlade Republike Hrvatske, ali sukladno statutima lokalnih jedinica odluku donosi sam čelnik ili je potrebna suglasnost predstavničkog tijela.

Krmpotić (2015) opisuje da *trgovačka društva u vlasništvu (ili suvlasništvu) lokalnih jedinica te ustanove kojima su oni osnivači, također prolaze zahtjevan proces prilikom zaduživanja te su i njima podloga proračuni, odnosno financijski planovi za buduće razdoblje*. Putem njih su definirani razvojni planovi koji za realizaciju trebaju dodatne izvore financiranja u vidu dugoročnog zaduženja (kreditnog, a vrlo rijetko i putem izdavanja obveznica) ili očekivani slabiji novčani tijek u određenom dijelu godine koji iziskuje kratkoročno zaduživanje. Sudjelovanje lokalne jedinice može biti direktno i indirektno. Naime, ukoliko se trgovačko društvo ili ustanova zaduži bez suglasnosti i bez jamstva lokalne jedinice (kratkoročno zaduženje ili dugoročno zaduženje koje nije za investiciju) može se reći da je lokalna jedinica ipak indirektno u tome sudjelovala. Razlog leži u činjenici da predstavnici izvršne vlasti *kontroliraju* navedena društva i ustanove putem sudjelovanja u radu nadzornih odbora i upravnih vijeća. Također, čelnik lokalne jedinice u pravilu obnaša i dužnost predsjednika skupštine tih trgovačkih društava i ustanova te imenuje ta nadzorna tijela. Imajući u vidu da je za dugoročno zaduživanje, u pravilu, potrebno prikupiti suglasnosti nadzornih tijela te suglasnost većinskog vlasnika ili osnivača, dok je kratkoročno zaduživanje obično u domeni uprave društva ili ravnatelja ustanove (obično definirano i društvenim ugovorom), svaka je pozitivna odluka tih tijela svojevrsna suglasnost lokalne jedinice. Izravno je sudjelovanje u procesu kada je od strane trgovačkog društva ili ustanove zatraženo da lokalne jedinice daju jamstva ili suglasnosti za zaduženje. Tada i formalno čelnik lokalne jedinice, odnosno njezino predstavničko tijelo, donosi odluku. Uprave tih trgovačkih društava i ravnatelji ustanova dužni su prije traženja suglasnosti svojih nadzornih tijela provesti nabavu financijskih sredstava (prikupiti jednu ili više ponuda). Nakon pozitivne odluke nadzornih tijela, prijedlog odluke o dugoročnom zaduženju za investiciju, a sukladno Zakonu o proračunu, dostavlja se na suglasnost većinskom vlasniku odnosno osnivaču.

Takva suglasnost dana ustanovama ulazi u kreditno zaduženje lokalne jedinice, dok suglasnost za trgovačka društva *opterećuje* zaduženost samo u slučaju negativnog poslovanja tog trgovačkog društva[91]. Svi sudionici navedenog procesa zaduživanja prikazani su i na slici br. 9.

Slika 9. Proces zaduživanja trgovačkih društava u vlasništvu lokalnih jedinica i ustanova kojima su lokalne jedinice osnivači

Izvor: Krmpotić (2015) temeljen na zakonskim propisima i aktima lokalnih jedinica.

Lokalna jedinica može i jamčiti za zaduženje trgovačkih društava u svome vlasništvu ili ustanova kojima su osnivači, ali samo nakon pozitivne odluke predstavničkog tijela i suglasnosti ministra financija. Navedena jamstva ulaze u kreditno zaduženje lokalne jedinice te su lokalne jedinice obvezne i izvještavati resorno ministarstvo o stanju aktivnih jamstava za koja je dana suglasnost.

Nakon prikupljenih svih suglasnosti te prema potrebi i jamstava lokalne jedinice, sklapanje ugovora o zaduženju u nadležnosti je uprave društva i ravnatelja ustanove. Uz to, dužni su redovito izvještavati lokalnu jedinicu o stanju takvih zaduženja. Sve navedeno prikazano je na slici br. 10.

[91] Rezultat prethodne godine u odnosu na godinu za koju se računa kreditna zaduženost.

Slika 10. Prikaz odnosa jamstava i suglasnosti ustanovama i trgovačkim društvima s kreditnom zaduženosti lokalne jedinice

Izvor: Krmpotić (2015) temeljem Zakona o proračunu.

3.3.5. Otplata kreditnih obveza i municipalnih obveznica

Realizacijom investicijskih aktivnosti odnosno dovršetkom ulaganja te nakon eventualnog moratorija započinje razdoblje otplate preuzetih obveza. Unatoč značajnim nominalnim proračunskim sredstvima, lokalne jedinice imaju određena ograničenja u pogledu korištenja sredstava za otplatu jer dio naplaćenih sredstava ima strogo propisanu namjenu. Primjerice riječ je o komunalnim prihodima, kao što su komunalni doprinos i komunalna naknada. Komunalni doprinos najčešće se koristi za financiranje izgradnje cesta, a komunalna naknada za održavanje cesta, a ti prihodi ne smiju se koristi za otplatu kredita, čak ni za kredite kojima je financirano ulaganje u cestovnu infrastrukturu. Nelogičnostima tu nije kraj, jer se navedena sredstva koriste prilikom izračuna koeficijenta zaduženosti, odnosno ubrajaju se u osnovicu prihoda. Lokalne jedinice otplaćuju svoj dug prema financijskim institucijama korištenjem općih proračunskih prihoda, ponajprije poreznih prihoda. Dodatno, za otplatu koriste se i prihodi od financijske imovine, zatim prihodi od iznajmljivanja imovine (nefinancijska imovina), pozitivna razlika između prihoda od prodaje nefinancijske imovine i rashoda za nabavu nefinancijske imovine te prihodi od kazni i administrativnih pristojbi. Važno je još istaknuti da se primitci od prodaje dionica i udjela u vlasništvu mogu koristiti samo za otplatu duga.

3.3.6. Refinanciranje i reprogramiranje duga

Lokalne jedinice povremeno imaju želju za refinanciranjem svojih kreditnih obveza. Iako je refinanciranje kratkoročnih kredita zakonom zabranjeno (članak 86.a Zakona o proračunu), gradovi koji imaju problema s likvidnosti često, pred istek ugovorenih godinu dana, otplate kratkoročni kredit i vrlo brzo ulaze u novi kratkoročni kreditni aranžman (u međuvremenu koriste druge poluge likvidnosti kao što je *faktoring* ili jednostavno povećaju dug prema dobavljačima). Pravo refinanciranje dopušteno je ukoliko se prilikom novog ugovaranja postignu povoljniji uvjeti od dotadašnjih uz obvezu da se inicijalno ugovoreni rok otplate kredita ne promijeni. Zadnjih nekoliko godina tržišni trend je pozitivan te dolazi do smanjenja cijene kredita koji su na raspolaganju lokalnim jedinicama primarno zbog visoke likvidnosti u bankarskom sektoru, ali i zbog krize uzrokovane virusom Covid-19 jer se u kriznim situacijama banke okreću financiranju manje rizičnih klijenata. Stoga je realno za očekivati da pojedine lokalne jedinice zatraže refinanciranje svojih kreditnih obveza.

Dodatno, lokalne jedinice mogu i svojim poslovnim rezultatima poboljšati svoj kreditni bonitet[92] što u pravilu financijske institucije honoriraju bolji kreditnim uvjetima kod sljedećih zaduživanja.

Postupak koji prethodi sklapanju novog ugovora o kreditu kojim se refinanciraju postojeće obveze identičan je procesu kod potpuno novog kreditnog zaduženja. Dakle, nakon odluke čelnika tijela i predstavničkog tijela, potrebna je i suglasnost Vlade Republike Hrvatske. Vlada će uskratiti svoju suglasnost ukoliko *otplata kredita istječe u proračunskoj godini u kojoj se traži refinanciranje, te ukoliko je ostatak duga veći od ukupnog iznosa duga prema odluci o davanju suglasnosti Vlade Republike Hrvatske temeljem koje je sklopljen ugovor* (članak 7. Pravilnika o postupku zaduživanja te davanja jamstava i suglasnosti jedinica lokalne i područne (regionalne) samouprave).

Ukoliko je lokalnoj jedinici potrebno produljenje roka otplate kredita, nije više riječ o refinanciranju nego reprogramiranju njezinih obveza. Reprogramirati se može dio kreditnih obveza ili cjelokupne kreditne obveza, a najčešće se za to pojavi potreba kada lokalne jedinice imaju značajniji pad prihoda (bilo zbog zakonodavnih promjena bilo zbog gospodarske krize) ili neočekivani porast troškova.

[92] *Bonitet je izraz koji izražava vrijednost, pouzdanost, poslovnu i posebice kreditnu sposobnost* (Mikić, Orsag, Pološki Vokić, Sunajko i Švaljek 2011: 64).

Financijske institucije ne reagiraju pozitivno prema takvim situacijama te tada u pravilu rastu troškovi financiranja te lokalne jedinice, ali lokalne jedinice prihvaćaju to produljenje roka otplate produljenje roka otplate (uz nepromijenjene ostale uvjete) preostale glavnice, čime se, uz prihvatljivo veće troškove, trenutno smanjuje pritisak na rashodovnu stranu proračuna (članak 7. a Pravilnika o postupku zaduživanja te davanja jamstava i suglasnosti jedinica lokalne i područne (regionalne) samouprave). Ponekad je dovoljno nekoliko mjeseci ili jedna proračunska godina kako bi se konsolidirale financije te se reprogramiranjem obveza može izbjeći situacija nemogućnosti plaćanja obveza na vrijeme i u punom iznosu[93].

U navedenoj situaciji, lokalne jedinice produljuju krajnji rok otplate kredita uz uvođenje moratorija[94] na otplatu kredita. Ukoliko lokalna jedinica dugoročno ne očekuje značajnije pozitivne promjene na prihodovnoj strani proračuna ili značajnija smanjenja proračunskih trošenja, najčešće koriste produljenje roka bez uvođenja moratorija.

Lokalna jedinica reprogramira svoju kreditnu obvezu sklapanjem dodatka ugovora s postojećim kreditorom nakon pozitivne odluke predstavničkog tijela. Lokalna jedinica obvezna je taj dodatak ugovoru dostaviti Ministarstvu financija u roku osam dana nakon njegova sklapanja.

Dodatno, prema Krmpotiću (2015) trebalo bi razmotriti postoji li potreba za uvođenje moratorija na otplatu duga uz zadržavanje istog krajnjeg roka. To trenutno zakonom nije predviđeno, a možda bi neke lokalne jedinice, temeljem očekivano boljih uvjeta za otplatu kredita u bliskoj budućnosti, pristale na moratorij nakon kojega bi im se povećale otplatne rate.

Financijske institucije mogu i iskazati nepovjerenje lokalnoj jedinici i ne odobriti reprogramiranje postojećih obveza. Situacija je ovo u kojoj je nužno žurno smanjenje proračunske potrošnje kako bi se otvorio prostor za nastavak urednog vraćanja kreditnih obveza.

[93] Neke su općine i gradovi zbog neracionalnog zaduživanja ili možda nerazumijevanja promijenjene financijske situacije od strane kreditora završile i u blokadi. Primjerice, u kolovozu 2010. godine Hypo Alpe-Adria-Bank d.d., Zagreb blokirala je račun grada Zlatara koji je bio prezadužen i nelikvidan.

[94] Moratorij predstavlja unaprijed definirano vremensko razdoblje u kojem su kreditor i dužnik ugovorili odgodu plaćanja (u pravilu) samo glavnice duga. Valja dodati i to da učestali moratoriji obično nisu u interesu niti kreditora niti dužnika. Naime, oni mogu kreditoru izazvati dodatne troškove koje mu nameće regulator odnosno HNB, dok se lokalnim jedinicama time povećava trošak tog zaduženja, a dugoročno i smanjuje bonitet.

4. Čimbenici vjerojatnosti neplaćanja i kreditni rejting

U današnje vrijeme riječ rejting (engl. *rating*) koristi se u raznim životnim aspektima, pa je tako sasvim uobičajeno da se govori o rejtingu države, poduzeća, političke stranke ili pak rejtingu neke osobe. Rejting predstavlja jednu vrstu mjere za kvalitetu ili uspjeh, a puni mu smisao daje mogućnost usporedbe rezultata temeljene na jednakom načinu ocjenjivanja odnosno jednakim parametrima temeljem kojih je rejting dan.

4.1. Kreditni rejting

Kreditni se rejting definira kao skup svojstava tražitelja kredita, kao što su položaj, imovina, poslovi i perspektiva, na temelju kojih je moguće donijeti ocjenu o njegovoj kreditnoj sposobnosti (Leko i Mates 1993: 253). *Tu ocjenu njegove kreditne sposobnosti, boniteta dužnika ili izdavatelja vrijednosnica, odnosno kreditni rejting analiziraju vjerovnici i investitori prije odobrenja kredita ili ulaganja u vrijednosnice države te financijskih i nefinancijskih institucija* (Bajo i Jurlina Alibegović 2008: 152). Najčešće se tu radi o bankama koje prate kretanje kreditnog rejtinga svojih zajmoprimaca (pa čak i podnositelja zahtjeva za kreditom) te o različitim fondovima zainteresiranima za ulaganje u dužničke vrijednosne papire ili vlasnički kapital. Svima je njima zajednička želja da, u konačnici, dobiju povrat svojih zajmova ili vlasničkih ulaganja uz očekivanu zaradu. Kako bi banke i fondovi smanjili troškove svojih procjena kreditnih sposobnosti te lakše i brže donijele odluke o ulaganju svojih sredstava, već dugi niz godina koriste kreditne rejtinge specijaliziranih rejting agencija. Rejting agencije rade svoje analize te na temelju tih analiza izdaju svoja mišljenja, na točno određeni datum, o kreditnoj sposobnosti pojedinog poduzeća, vrijednosnice ili duga.[95] Bitno je naglasiti, a to kontinuirano napominju i sve rejting agencije, da dodijeljeni kreditni rejting predstavlja samo njihovo mišljenje pri čemu to njihovo mišljenje ne predstavlja preporuku za kupovinu, ni preporuku za prodaju, niti preporuku za držanje neke vrijednosnice u svome vlasništvu. Radi se o složenoj ocjeni kojom agencija sublimira povijesne i tekuće podatke te buduća očekivanja vezana za izdavatelja, zatim podatke o konkurenciji i tržištu na kojem izdavatelj posluje. Kreditni rejting formalno ne predstavlja preporuku, ali svi sudionici financijskog tržišta koriste kreditne rejtinge rejting agencija kod formiranja cijene i donošenja odluke o ulaganju.

[95] U.S. Securities and Exchange Commission (2003). *Report on the Role and Function of Credit Rating Agencies in the Operation of the Securities Markets*. https://www.sec.gov/news/studies/credratingreport0103.pdf (pristupljeno: 30. studenog 2020.).

Temeljni čimbenik, koji utječe na cijenu, predstavlja rizik vezan za vjerojatnost povrata uloženih sredstava ili podmirenja financijskih obveza, stoga je i osnovna svrha rejtinga kvantificirati razine vjerojatnosti neispunjenja obveza, odnosno glavna je aktivnost rejting agencija skaliranje tih vjerojatnosti (Langohr i Langohr 2008: 7). Što je veći rizik i veća neizvjesnost oko povrata ulaganja, investitori traže veću premiju rizika, odnosno veću kamatnu stopu. Bitno je naglasiti kako kreditni rejting ne utvrđuje u potpunosti cijenu neke vrijednosnice ili duga (ali značajno na nju utječe) budući da je vjerojatnost neispunjenja obveza samo jedan faktor kod formiranja tražene cijene od strane kreditora ili investitora, dok je drugi faktor rizik tržišta (engl. *market risk*) (Langohr i Langohr 2008).

Različita su tumačenja pojma neispunjenja obveza (engl. *default*). Naime, za neke tržišne dionike i teoretičare je do neispunjenja obveza došlo u trenutku kada prva dospjela obveza nije plaćena na vrijeme ili u punom iznosu i to je definicija koja se upotrebljava u ovoj doktorskoj disertaciji. Za druge neispunjenje obveza nastaje tek protekom određenog vremena (60 ili 90 dana) nakon prve nemogućnosti plaćanja, a za ostale tek proglašenjem bankrota. Dodatno, za dio kreditora postoji razlika između trenutne i trajne nemogućnosti ispunjenja obveza, gdje trenutna nemogućnost ne mora nužno završiti bankrotom.

Iako sama definicija u središte pojma kreditnog rejtinga stavlja poduzeća, kreditni se rejting dodjeljuje i državama te jedinicama lokalne i regionalne samouprave. Visok kreditni rejting sugerira nizak rizik nemogućnosti plaćanja obveza te stoga u konačnici smanjuje i troškove zaduživanja. Dodatno, rast kreditnog rejtinga, vezan za lokalne jedinice vlasti, može[96]:

1. *proširiti broj investitora voljnih za kupovinu vrijednosnice*
2. *učiniti dug atraktivnijim za domaće i strane investitore*
3. *pružiti besplatni publicitet vezan za financijsko stanje lokalnih jedinica*
4. *direktno utjecati na buduće odluke lokalnih čelnika*.

4.1.1. Povijesni pregled kreditnog rejtinga

Razvoj izvještaja, koji se smatraju pretečama današnjih kreditnih rejtinga, temeljem kojih su investitori mogli donositi kvalitetnije odluke, započeo je još u 19. stoljeću, dok se početkom 20. stoljeća osnivaju prve rejting agencije (tablica br. 16). Primjerice, prvo izdanje *The American Railroad Journala*, izašlo je davne 1832. godine, a s vremenom je Henry Poor transformirao navedenu publikaciju u publikaciju namijenjenu investitorima u američke

[96] The World Bank (1999): Credit ratings and Bond Issuing at the Subnational Level, Training Manual.

željeznice prateći operativnu i financijsku statistiku poduzeća tog vremena. Trgovačka agencija osnovana 1841. godine predstavlja prvu trgovačku kreditnu agenciju koja je kroz mrežu agenata u SAD-u skupljala informacije o poslovnim rezultatima poduzeća i prodavala te informacije pretplatnicima. U tom periodu i John Bradstreet osniva svoju agenciju, a Robert Dun preuzima Trgovačku agenciju.

Tablica 16. Povijesni pregled razvoja kreditnih rejting agencija

<table>
<tr><th colspan="5">Razvoj prije osnivanja prve kreditne rejting agencije</th></tr>
<tr><td>1832.</td><td colspan="2">1841.</td><td colspan="2">1849.</td></tr>
<tr><td>Prvo izdanje The American Railroad Journal</td><td colspan="2">Prva trgovačka kreditna agencija (preuzima ju Robert Dun 1859. godine)</td><td>Poor izdaje Manual of the Railroads of the United States</td><td>John Bradstreet osniva agenciju</td></tr>
<tr><th colspan="5">Prva faza (1909. – 1943.)</th></tr>
<tr><td>1909.</td><td>1916.</td><td>1930.</td><td>1933.</td><td>1941.</td></tr>
<tr><td>John Moody osniva agenciju</td><td>Poorova kompanija počinje izdavati rejtinge. John Knowles Fitch osniva Fitch Ratings.</td><td>Prva upotreba kreditnog rejtinga u regulatorne svrhe.</td><td>Spajanje Dun & Bradstreet (D&B)</td><td>Spajanje Poor company sa Standard Statistics (S&P)</td></tr>
<tr><th>Druga faza (1944. – 1969.)</th><th colspan="4">Treća faza (1970. – 2001.)</th></tr>
<tr><td>1962.</td><td>1970.</td><td>1975.</td><td>1995.</td><td>2000.</td></tr>
<tr><td>D&B preuzima Moody's Investor Services</td><td>Uvodi se plaćanje rejtinga od strane izdavatelja.</td><td>SEC izdaje službenu listu Nacionalno priznatih statističkih rejting organizacija (NRSRO).</td><td>Fimalac SA preuzima Fitch Ratings</td><td>Fitch rating preuzima Buff & Phelps Credit Rating Co.</td></tr>
<tr><td colspan="5">Četvrta faza (2002. – danas)</td></tr>
</table>

Izvor: Prikaz autora na temelju Langohr, H. M., Langohr P. T. (2008: 376)

Prva faza, prikazana u tablici br. 16, vezana je za razdoblje netom prije Prvog svjetskog rata[97], a trajala je sve do početka Drugog svjetskog rata te je zadnji dio promatranog perioda obilježio snažni gospodarski rasta i velik broj izdanih rejtinga. Prvu agenciju, koja je uz pregled poslovanja koristila i analizu rizika za izradu kreditnog rejtinga, osnovao je John Moody 1909. godine. Vrlo brzo nakon toga (1916. godine) i agencija koju je osnovao Henry Poor počinje izdavati rejting procjene, a iste godine John Knowles Fitch osniva svoju rejting agenciju.

[97] Prvi svjetski rat trajao je od 1914. do 1918. godine, a drugi svjetski rat od 1939. do 1945. godine.

Jedno stoljeće kasnije te tri agencije imaju vodeću ulogu na cjelokupnom svjetskom tržištu te *pokrivaju* preko 95 % svih dodijeljenih rejtinga. Velika promjena u odnosu između rejtinga agencija i tržišta obveznica dogodila se početkom 1930-ih godina. Naime, *regulatori bankovnog tržišta usmjeravali su banke na ulaganja u sigurne obveznice koje imaju investicijski rejting te su im vrlo brzo uveli i zabranu ulaganja u obveznice špekulativnog rejtinga, a banke su bile osuđene na korištenje izdavača službenih rejting priručnika*.[98] (White 2010: 213) Tijekom godina koje su slijedile, agencije Dun i Bradstreet su se spojile, da bi na koncu preuzele Moody's Investor Services, odnosno agenciju koju je osnovao John Moody. Agencija koju je osnovao Henry Poor spojila se 1941. godine s agencijom Standard Statistics te i dan danas posluju pod nazivom Standard & Poor's (S&P).

Druga faza, prema H. i P. Langohr, *započela je nakon Drugog svjetskog rata i trajala do kraja 60-ih godina prošlog stoljeća*. To je faza ekonomske stabilnosti i niske potražnje za kreditnim rejtinzima, odnosno svojevrsne stagnacije tržišta kreditnog rejtinga.

Treća faza započinje početkom 70-ih godina i traje sve do početka novog tisućljeća, odnosno do 2001. godine (grafikon br. 1).

Grafikon 1. Pregled rasta broja kreditnih rejtinga od 1970. do 2017. godine

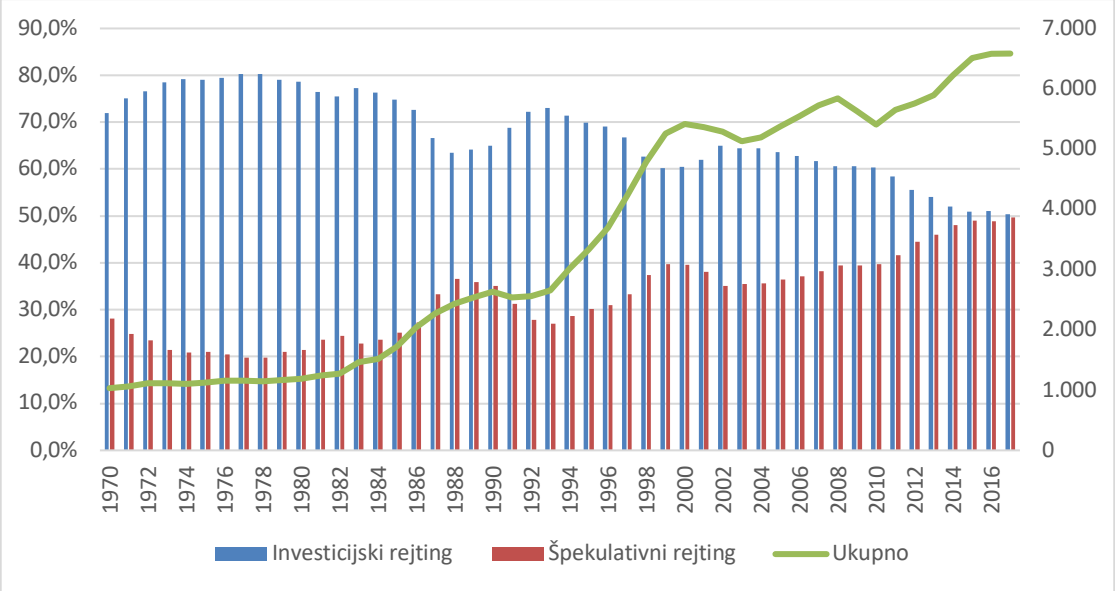

Izvor: Prikaz autora na temelju podataka Moody's Investors Service (2018)[99]

[98] Engl. Recognized rating manuals
[99] *Annual Default Study: Corporate Default and Recovery Rates*, 1920 – 2017. https://www.moodys.com/researchdocumentcontentpage.aspx?docid=PBC_1112754 (pristupljeno: 28. studenoga 2020.).

Razdoblje je to velikih ekonomskih šokova te kontinuiranim porastom za uslugama kreditnih rejting agencija, odnosno snažnim rastom broja kreditnih rejtinga. Početkom 70-ih godina prošlog stoljeća došlo je do velike promjene u poslovnom modelu triju najvećih rejting agencija. Naime, dosadašnji model u kojem investitor plaća izradu kreditnog rejtinga zamijenjen je modelom u kojem izdavač plaća izradu rejtinga. Potencijalnih je razloga nekoliko (White 2010: 214):

1. *strah da će doći do pada prodaje rejting priručnika (engl. rating manual) zbog nadolazeće tehnologije – brzih fotokopirnih uređaja*
2. *bankrot nekih izdavatelja*[100] *šokirao je tržište obveznica te su ostali izdavatelji odlučili platiti izdavanje rejtinga od rejting agencija kako bi one, na neki način, jamčile da su zaista niskog rizika*
3. *promjena u regulativi koja je značila da financijske institucije u svom portfelju mogu imati samo vrijednosne papire 'verificirane' od rejting agencija te su stoga izdavatelji bili voljni platiti kako bi dobili priliku sredstva tražiti od financijskih institucija*
4. *kao i svaki drugi oblik industrije informacija, izdavanje rejtinga može biti plaćeno od obje strane sudionika tržišta*.

Neovisno o razlozima, promjena poslovnog modela omogućila je potencijalne sumnje u sukob interesa gdje bi izdavatelj mogao platiti *bolji* rejting, što bi u konačnici trebalo smanjiti cijenu financiranja. Rejting agencije tvrde da je njima na prvom mjestu njihova dugoročna reputacija. Oni ju ne žele ugroziti na način da nekome pogoduju pa da taj na kraju ne izvrši svoje financijske obveze. Pavković potvrđuje tu tezu odnosno smatra da je *glavni mehanizam regulacije i jamstva kvalitete dodijeljenih rejtinga reputacijski kapital* (Pavković, 2012). Taj reputacijski kapital izgrađuje se godinama, a osim kvalitete danih rejtinga ogleda se i kroz transparentnost podataka koju ponajviše cijene investitori te čuvanje tajnih podataka što je neizmjerno bitno izdavateljima. Komisija za vrijednosnice i burze u SAD-u (engl. *SEC: The U.S. Securities and Exchange Commission*) od 1975. godine izdaje službenu listu Nacionalno priznatih statističkih rejting organizacija (engl. *NRSRO: Nationally recognized statistical rating organisation*), a prema izvještaju iz siječnja 2020. godine bilo je 10 registriranih rejting agencija (tablica br. 17). Prema podatcima koje su rejting agencije predale prilikom godišnjeg certificiranja, ukupno su svi imali preko 2,1 milijun važećih, izdanih rejtinga na kraju 2018.

[100] Npr. Penn-Central Railroad 1970.

godine. Najveća agencija prema tom pokazatelju je S&P s gotovo polovinom od svih izdanih rejtinga odnosno preko milijun izdanih rejtinga, a slijede ju Moody's sa skoro 691 tisućom (32,3 %) te Fitch s gotovo 280 tisuća (13,5 %).

Tablica 17. Lista priznatih rejting organizacija (*NRSRO*) u SAD-u

Puni naziv	Skraćeni naziv	Broj rejtinga	Udio u %
A.M. Best Rating Services, Inc.	A.M. Best	8.253	0,39 %
DBRS, Inc.	DBRS	51.131	2,39 %
Egan-Jones Ratings Company	EJR	19.094	0,89 %
Fitch Ratings, Inc.	Fitch	288.251	13,49 %
HR Ratings de México, S.A. de C.V.	HR Ratings	1.243	0,06 %
Japan Credit Rating Agency, Ltd.	JCR	3.882	0,18 %
Kroll Bond Rating Agency, Inc.	KBRA	12.316	0,58 %
Moody's Investors Service, Inc.	Moody's	690.923	32,34 %
Morningstar, Inc.	Morningstar	3.313	0,16 %
S&P Global Ratings	S&P	1.058.211	49,53 %
Ukupno		**2.136.617**	**100,00 %**

Izvor: Izračun autora na temelju podataka iz Annual Report on Nationally Recognized Statistical Rating Organizations[101]

U Europskoj je uniji situacija nešto drugačija. Naime, regulator je Europska agencija za vrijednosne papire i tržište kapitala (engl. *ESMA*[102]) te je za rad na području unije bilo registrirano ili certificirano 42 rejting agencija[103] (najviše iz Njemačke - osam, Velike Britanije - šest te Španjolske i Italije po četiri). Važno je napomenuti da, iako Fitch i Moody's imaju po sedam registriranih podružnica u zemljama Europske Unije, značajno je veći broj rejting agencija koje djeluju na području Europske unije u odnosu na one koje djeluju u SAD-u. U Republici Hrvatskoj nije registrirana niti jedna rejting agencija, ali neovisno o tome regulaciju provedbe europske legislative vezane za kreditne rejting agencije vrše Hrvatska narodna banka (HNB) i Hrvatska agencija za nadzor financijskih usluga (HANFA)[104]. Navedene su institucije, primjerice, zadužene za kontrolu usklađenosti dodijele rejtinga na području Republike Hrvatske od strane rejting agencija registriranih u *trećim* zemljama sukladno članku 25. Uredbe (EZ) br. 1060/2009 Europskog parlamenta i Vijeća od 16. rujna 2009. o agencijama za kreditni rejting[105].

[101] https://www.sec.gov/files/2019-annual-report-on-nrsros.pdf (pristupljeno: 6. 11. 2020.)
[102] *European Securities and Markets Authority*
[103] Prema podatcima ESMA-e https://www.esma.europa.eu/supervision/credit-rating-agencies/risk (pristupljeno: 1. studenoga 2020.).
[104] https://www.esma.europa.eu/sites/default/files/cra_regulation.pdf (pristupljeno: 22. lipnja 2020.).
[105] Dostupno na: https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:32009R1060&from=HR (pristupljeno: 30. studenoga 2020.).

4.1.2. Rejting agencije

Rejting agencije, od onih najmanjih na tržištu pa sve do tri najveće agencije koje praktično imaju oligopol na tržištu rejtinga, imaju jednaku ulogu. Njihova je uloga *u smanjenju asimetričnih informacija između investitora i izdavatelja dužničkih vrijednosnica* (Elkhoury 2008), odnosno njihov je cilj izbjeći asimetrične informacije između obje tržišne strane korištenjem standardiziranih pokazatelja kvalitete (Kuhner 2001: 2). Svim je agencijama zajedničko da, kod procjene rejtinga, evaluiraju postojeće podatke, ali i planove, te stoga dodijeljeni rejting odražava i buduća očekivanja rejting agencija. *Ne postoji univerzalna formula određivanja rejting ocjene zbog toga što je procjena rizičnosti izdavatelja posao koji, osim objektivne procjene financijskih i ekonomskih pokazatelja koje analitičari imaju na raspolaganju, sadrži i subjektivnu procjenu* (Pavković i Vedriš 2011: 235).

Objektivnu procjenu izrađuju koristeći *scorecard* pristup u obradi javno dostupnih podataka i podataka koje dobiju od izdavatelja (ključni financijski pokazatelji uglavnom se koriste na godišnjoj razini). Tijekom procesa izrađivanja konačne ocjene, objektivni, kvantitativni rezultati prilagođavaju se kvalitativnim pokazateljima.

Dakle, načela djelovanja rejting agencija, sukladno odredbama Međunarodne organizacije regulatora tržišta kapitala[106], mogu se sažeti u nekoliko točaka:

1. izdavanje rejtinga treba smanjiti informacijsku asimetriju
2. izdavanje rejtinga treba biti neovisno i objektivno
3. rejting agencije trebaju težiti transparentnosti i potpunom prikazu informacija
4. rejting agencije trebaju čuvati sve tajne podatke.

Bitno je napomenuti da sve tri velike agencije imaju posebna pravila odnosno rejting metodologije za različite vrste procjene rejtinga. Metodologije se razlikuju ovisno o vrsti izdavatelja, sektoru iz kojeg dolazi, vrsti vrijednosnice za koju se rejting izdaje, području djelovanja izdavatelja i sl. Velike rejting agencije koriste na desetke različitih vrsta metodologija. Različite metodologije primjenjuju se za banke, poduzeća, države i jedinice lokalne i regionalne vlasti.

[106] The Technical Committee of the International Organisation of Securities Commissions (2003). *Report on the activities of credit rating agencies*. https://www.iosco.org/library/pubdocs/pdf/IOSCOPD153.pdf (pristupljeno: 30. 11. 2020.).

Također, metodologija se mijenja ovisno o području, tako primjerice postoji jedna metodologija izdavanja rejtinga za jedinice lokalne i regionalne vlasti s područja Sjedinjenih Američkih Država, dok posebna pravila i druge vrste metodologija vrijede za ostatak svijeta. O izdavatelju, dostupnim podatcima i primijenjenoj metodologiji ovisi i dugotrajnost procesa izdavanja ili revizije pojedinog rejtinga. Prema Svjetskoj banci[107] izdavanje rejtinga za lokalne i regionalne razine vlasti za pojedini dug traje u prosjeku 60 dana.

Postupak započinje zahtjevom izdavatelja za rejtingom duga, te nakon toga tim iz rejting agencije dolazi kod izdavatelja i uzima sve potrebne podatke. Nakon toga rejting agencija analizira podatke, odbor za dodjelu rejtinga izglasava rejting te se on prezentira izdavatelju. U tom trenutku izdavatelj može prihvatiti predloženi rejting ili se žaliti te rejting agenciji dostaviti još podataka kako bi opravdao svoju žalbu te želju za boljim rejtingom. Nakon završetka tog procesa, izdaje se formalna obavijest o danom rejtingu te rejting agencija nadzire dug do njegovog dospijeća.

Agencija Standard and Poor's (S&P) svoju rejting metodologiju za lokalne i regionalne vlasti izvan Sjedinjenih Američkih Država (engl. *International Public Finance: Methodology For Rating Local And Regional Governments Outside Of The U.S., 2019*) temelji na kvalitativnim i kvantitativnim faktorima te na dvjema osnovnim komponentama. Prvu komponentu čini zakonodavni okvir, a drugu individualni kreditni profil (engl. *individual credit profile*). Ocjenjivanje zakonodavnog okvira uglavnom je kvalitativno, a odnosi se na utjecaj raznih pravila, zakona, ali i prakse na funkcioniranje jedinica vlasti. Tri su faktora koji se procjenjuju, a radi se o predvidivosti, uravnoteženosti prihoda i rashoda te transparentnosti i odgovornosti (tablica br. 18).

Predvidivost ima 25 % utjecaja na konačnu ocjenu, a S&P analizira učestalost reformi koje utječu na jedinice vlasti, predvidivost ishoda reformi te mogućnost utjecaja na više razine vlasti osobito ako će izmjene zakonodavnog okvira imati utjecaj na financijsko funkcioniranje jedinice vlasti. Uravnoteženost prihoda i rashoda ima 50 % utjecaja na konačnu ocjenu, a odnosi se na fiskalnu održivost u budućnosti.

Transparentnost i odgovornost imaju 25 % utjecaja na konačnu odluku, a procjenjuje se primjena standarda kod izvještavanja i planiranja te odgovornost vodećih ljudi (dužnosnika, pročelnika i sl.) jedinice vlasti.

[107] The World Bank (1999): Credit ratings and Bond Issuing at the Subnational Level. Training Manual. 6-11 str.

Tablica 18. Pregled varijablā koje koristi agencija Standard and Poor's

Zakonodavni okvir	Gospodarstvo
Predvidivost	BDP po stanovniku
Uravnoteženost prihoda i rashoda	Rast BDP-a
Transparentnost i odgovornost	Gospodarska koncentracija i volatilnost
Financijski menadžment	Socioekonomski profil
Politička i menadžerska snaga	**Likvidnost**
Financijsko planiranje i implementacija	Koeficijent pokrića duga
Likvidnost, dug i upravljanje potencijalnim obvezama	Pristup izvorima financiranja
Izvršenje proračuna	**Dug**
Volatilnost novčanog tijeka	Struktura duga
Udio operativnog rezultata u prilagođenom operativnom prihodu	Trošak duga
Udio prilagođenog stanja na računu u ukupnim prilagođenim prihodima	Potencijalne obveze

Izvor: Prikaz autora na temelju podataka Standard & Poor's Financial Services (2019)[108]

Individualni kreditni profil sastoji se od pet faktora, a to su: gospodarstvo (engl. *Economy*), financijski menadžment (engl. *Financial Management*), izvršenje proračuna (engl. *Budgetary Performance*), likvidnost (engl. *Liquidity*) i dug (engl. *Debt Burden*). Svi imaju jednak utjecaj na konačnu ocjenu, odnosno svaka pojedinačna ocjena ima 20 % utjecaja na ukupnu ocjenu kreditnog profila.

Procjena gospodarstva započinje BDP-om po stanovniku, a može se dodatno prilagoditi faktorima kao što su: perspektive rasta, industrijska koncentracija i socioekonomski profil jedinice vlasti. Primjerice, uspoređuje se rast realnog BDP-a lokalne ili regionalne jedinice s rastom državnog BDP-a te ovisnost regije ili grada o jednoj industrijskoj grani. Završni dio procjene gospodarstva sastoji se od socioekonomskog profila odnosno, procjenjuje se razlika od nacionalnog prosjeka te utjecaj na financijsku sliku jedinice vlasti.

Financijski menadžment pretpostavlja kvalitativne analize političkih i menadžerskih snaga, odnosno disciplinu vodstva jedinice vlasti i njihovu sposobnost i volju da dugoročno vode održivu fiskalnu politiku. Također, procjenjuje se kvaliteta planiranja i implementacije dugoročnih planova koji odražavaju volju za financijski stabilnim poslovanje.

[108] International Public Finance. Methodology For Rating Local And Regional Governments Outside Of The U.S. https://www.standardandpoors.com/en_US/web/guest/article/-/view/sourceId/10969943 (pristupljeno: 2. svibnja 2020.).

Agencija S&P procjenjuje i želju čelnika jedinice vlasti za novim zaduživanje, procjenjuje i upravljanje likvidnošću te upravljanje potencijalnim obvezama.

Kod izvršenja proračuna ponajprije se procjenjuje visina i volatilnost očekivanih novčanih tijekova kojima bi se trebao otplaćivati postojeći dug. Dva su ključna omjera: operativni rezultat (engl. *operating balance*) u odnosu na prilagođeni operativni prihod (engl. *adjusted operating revenues*) te saldo računa kapitalnih transakcija (engl. *balance after capital accounts*) u odnosu na ukupni prilagođeni prihod (engl. *total adjusted revenues*). Naime, operativni rezultat agencija S&P računa kao rezultat prilagođenog[109] operativnog prihoda umanjenog za prilagođene operativne rashode. U operativni prihod uključuju se svi prihodi jedinice vlasti (porezni prihodi, prihodi od zakupa, razne naknade, koncesije i sl.), ali se isključuju kapitalne subvencije, prihodi od prodaje imovine i prihodi od danih zajmova. Saldo računa kapitalnih transakcija podrazumijeva operativni rezultat uvećan za kapitalne prihode te umanjen za kapitalne troškove (troškovi popravaka i zamjene postojeće infrastrukture te razvoja nove infrastrukture). Osim navedena dva omjera, analiziraju se i proračunski trendovi i fleksibilnost, te proračunske oscilacije.

Procjena likvidnosti fokusira se na podudarnost postojećih izvora financiranja (internih i eksternih) po pitanju pravovremenog i potpunog plaćanja duga. Agencija S&P prvo utvrdi koeficijent pokrića duga (engl. *Debt service coverage ratio*) te zatim kvalitativno procjenjuje mogućnosti pristupa vanjskim izvorima financiranja. Najvišu ocjenu vezanu za pokriće duga dobiju jedinice vlasti koje mogu slobodnom gotovinom (engl. *total free cash*)[110] umanjenom za ugovoreno financiranje pokriti više od 100 % duga koji dolazi na naplatu.

Konačni dio ocjene čini procjena tereta duga, odnosno procjena koliko će u budućnosti povrat glavnice i plaćanje kamata predstavljati opterećenje za proračun jedinice vlasti. Dva su ključna pokazatelja i odnose se na omjer zaduženja poduprtog porezima (engl. *tax-supported debt*) u odnosu na konsolidirani operativni prihod (engl. *consolidated operating revenues*) te trošak direktnog duga (engl. *interest payment*) u odnosu na prilagođeni operativni prihod. Zaduženje poduprto porezima se sastoji od direktnog duga jedinice vlasti, duga poduzeća koja su u vlasništvu jedinice vlasti te preostalog dijela duga za koji su dane garancije.

[109] Prilagodba prihoda i rashoda vezana je za nenovčane stavke (primjerice amortizaciju) te prolazne stavke (primjerice transfere).

[110] Slobodna gotovina podrazumijeva prilagođenu gotovinu (gotovinu na raspolaganju u sljedećih 12 mjeseci) uvećanu za ostala likvidna sredstva, saldo računa kapitalnih transakcija te već ugovorena financiranja (kratkoročna i dugoročna) koja su na raspolaganju za potrošnju u sljedećih 12 mjeseci.

Nakon kvantitativne analize duga, izrađuje se i kvalitativna prilagodba vezana za strukturu duga, izloženost riziku valute, kamatne stope i sl. Dodatna prilagodba vezana je za potencijalne obveze koje u budućnosti mogu postati stvarna obveza jedinica vlasti te se nakon toga izrađuje konačna procjena.

Agencija Moody's svoju rejting metodologiju za lokalnu i regionalnu vlast (engl. *Regional and Local Governments, Rating methodology, 2018*) temelji na dvije osnovne komponente. Prva je osnovna kreditna procjena (engl. *Baseline credit assessment*), a druga vjerojatnost izvanredne pomoći od više razine vlasti u slučaju nemogućnosti plaćanja dospjelih obveza (maksimalna zaštita ogleda se u situaciji u kojoj država u potpunosti garantira za obveze podređenih razina vlasti). Kombinacija te dvije komponente u konačnici kreira kreditni rejting.

Osnovna kreditna procjena sastoji se od specifičnog rizika (engl. *idiosyncratic risk*) koji se izračunava za svaku pojedinu lokalnu ili regionalnu jedinicu temeljem *scorecarda*, sistemskog rizika (engl. *systemic risk*) koji je temeljen na rejtingu države te eventualne procjene dodatnih faktora koji mogu utjecati na kreditnu procjenu. Specifični rizik izračunava se putem četiri ključna faktora prikazana u tablici br. 19 od kojih financijska pozicija i dug (engl. *Financial Performance and Debt Profile*) te javno upravljanje i menadžment (engl. *Governance and Management*) imaju svaki po 30 % udjela u konačnoj ocjeni, a preostali pokazatelji po 20 % udjela u konačnoj ocjeni.

Tablica 19. Pregled varijablā koje koristi agencija Moody's

Osnovni ekonomski pokazatelji	**Zakonodavni okvir**
Gospodarska snaga - BDP po stanovniku	Zakonodavni temelj
Gospodarska volatilnost	Financijska fleksibilnost
Financijska pozicija i dug	**Javno upravljanje i menadžment**
Operativna marža	Upravljanje rizikom i financijama
Kamate	Upravljanje investicijama
Likvidnost	Upravljanje dugom
Iznos i struktura duga	Transparentnost i revizija

Izvor: Prikaz autora na temelju podataka Moody's Investors Service (2018)[111]

Osnovni ekonomski pokazatelji (engl. *Economic Fundamentals*) sastoje se od gospodarske snage i volatilnosti. Naime, Moody's izračunava gospodarsku snagu temeljem odnosa lokalnog ili regionalnog BDP-a po stanovniku s nacionalnim BDP-om po stanovniku, te ukoliko je BDP

[111] Regional and Local Governments. Rating methodology. https://www.moodys.com/research documentcontentpage.aspx?docid=PBC_1091595 (pristupljeno: 1. svibnja 2020).

po stanovniku iznad državnog prosjeka, utjecaj na rejting je pozitivan. Gospodarska volatilnost temeljena na stupnju industrijske koncentracije u nekom gradu ili na nekom području dodatno utječe na rejting. Limitirana koncentracija odnosno, gospodarstvo koje je jako diverzificirano, može se lakše nositi s potencijalnim kriznim situacijama ili cikličkim promjenama te postoje pozitivna promišljanja s aspekta rejtinga.

Zakonodavni okvir sastoji se od zakonodavnog temelja (engl. *Legislative background*) i financijske fleksibilnosti. Moody's procjenjuje odnos centralne vlasti s lokalnim i regionalnim jedinicama kroz analizu zakona, pravilnika i ustaljene prakse te procjenjuje dane odgovornosti i podudarnost fiskalne snage za provedbu danih odgovornosti. Dodatno se procjenjuje i fleksibilnost koju imaju niže razine vlasti u promjeni tog okvira prilikom prilagodbe na različite promjene. U pravilu bolju ocjenu dobiju zakonodavni okviri koji omogućuju jasno definirane i predvidive prihode, zatim jasne i stabilne obveze te okviri koji omogućuju i veću fiskalnu fleksibilnost (individualne promjene u značajnom dijelu operativnog prihoda) i učinkovitiji nadzor od strane središnje vlasti (ograničenje nad procesom zaduživanja, redovnim izvještavanjem, ovlast za provođenje revizije i sl.). Također, bitno je naglasiti da sve lokalne i regionalne jedinice u istoj državi dobiju istu ocjenu vezanu za zakonodavni okvir.

Procjena financijske pozicije i osobina duga lokalnih i regionalnih jedinica treća je komponenta koju Moody's procjenjuje. Najvažniji je pokazatelj kreditne snage dugoročno izbalansirani proračun. Naglasak pri procjeni prihoda stavljen je na operativnoj marži (engl. *operating margin*) kao rezultatu odnosa operativnog rezultata (engl. *gross operating balance*) i operativnih prihoda (engl. *operating revenues*) dok je kod rashoda naglasak na teretu kamata izračunatom kao omjer plaćenih kamata i operativnih prihoda. Najveći utjecaj na konačnu ocjenu iz treće komponente imaju likvidnost i dug. Pozitivnim se ocjenjuje ukoliko jedinica primjereno upravlja novcem i cjelokupnom svojom likvidnošću te ukoliko nema potrebe za dodatnom likvidnošću ili ima neupitan pristup dodatnoj likvidnosti na tržištu. Što se tiče duga, pozitivnim se smatra nizak udio direktnog i indirektnog duga u odnosu na operativni prihod te nizak udio kratkoročnog i direktnog duga u ukupnom direktnom dugu. Kod definiranja ukupnog duga, uključuje se i dug za koji je jedinica dala garanciju kao i dug javnih poduzeća u većinskom vlasništvu jedinica za koji nije izdana garancija. Također, procjenjuju se i buduće potrebe za zaduživanjem.

U završnom dijelu procjene specifičnog rizika procjenjuje se sposobnost vlasti da donosi financijske odluke, zatim praksa u financijskom upravljanju te transparentnost.

Naime, pozitivnim se ocjenjuje visoka kvaliteta internih kontrola i kvaliteta planskog procesa. Pozitivnim se ocjenjuje i kvalitetno upravljanje investicijama te upravljanje dugom kako bi se izbjegla izloženost bilo kojem riziku. Transparentnost i kvaliteta te pravovremenost javno dostupnih informacija o poslovanju dodatni su faktor koji se procjenjuje.

Drugi dio osnovne kreditne procjene vezan je za sistemski rizik te on u pravilu korespondira s rejtingom države u kojoj se lokalna ili regionalna jedinica nalaze. U pravilu, rejting države predstavlja gornju granicu rejtinga koji njima može biti dodijeljen zbog snažne korelacije koju različite razine vlasti imaju.

Unatoč sveobuhvatnim analizama rejtinga agencija, Gaillard (2009) napominje da *tri varijable: indikator defaulta države, BDP po stanovniku, te pokazatelja zaduženosti (engl. debt ratio) objašnjavaju preko 80 % rejtinga lokalnih i regionalnih vlasti koje je dodijelila agencija Moody's*.

Dodjela kreditnih rejtinga lokalnim jedinicama 80-ih godina prošlog stoljeća bila je na vrlo niskim razinama, da bi do snažnog porasta došlo početkom 21. stoljeća (grafikon br. 2).

Grafikon 2. Kretanje broja dodijeljenih kreditnih rejtinga lokalnih i regionalnih vlasti od strane agencije Moody's u razdoblju 1983. do 2017. godine

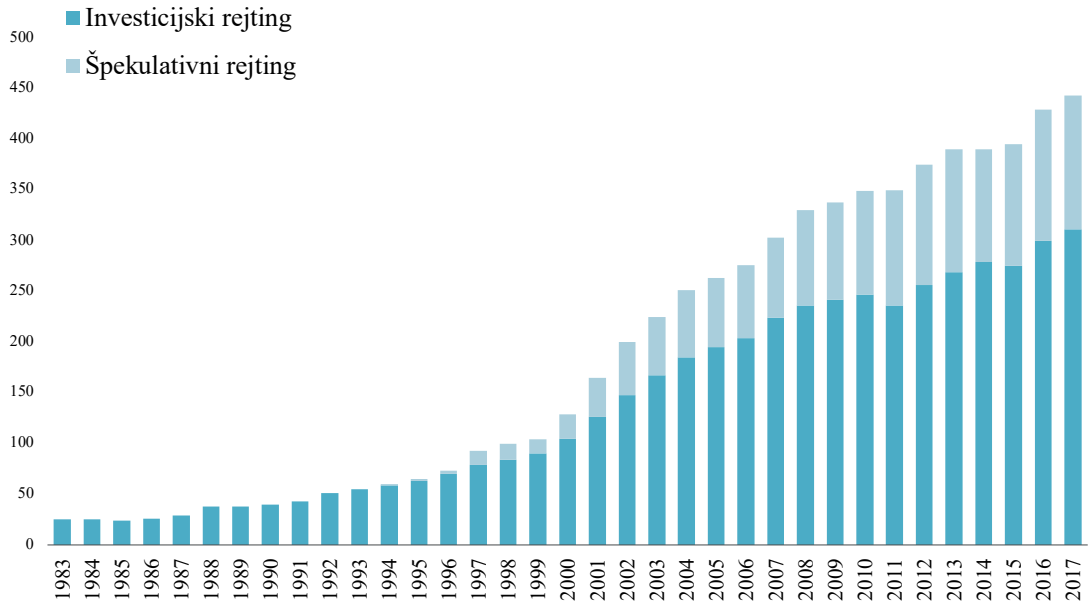

Izvor: Prikaz autora temeljen na podatcima Moody's Investor Service (2019)[112]

[112] *Sub-Sovereign Default and Recovery Rates. 1983-2018H1.* https://www.moodys.com/research documentcontentpage.aspx?docid=PBC_1110109 (pristupljeno: 26. studenoga 2020.).

U promatranom je razdoblju došlo do porasta broj kredita koji imaju špekulativni rejting jer je sve veći broj zemalja u razvoju dobilo mogućnost rejtinga, ali i pristupa vanjskim izvorima kapitala. Na kraju promatranog razdoblja, udio kredita sa špekulativnim rejtingom porastao je na 30 %.

Agencija Fitch koristi pet kriterija kod dodjeljivanja novog rejtinga ili ponovne procjene postojećeg rejtinga za lokalne i regionalne vlasti izvan Sjedinjenih Američkih Država (engl. *International Local and Regional Governments Rating Criteria-Outside the United States, 2016*) odnosno za izražavanje njihovog *mišljenja* o osjetljivosti na nemogućnost izvršenja financijskih obveza. Za njih zakonodavni okvir predstavlja polazišnu osnovu kod procjene rejtinga te je najvažniji kvalitativni faktor. Preostala četiri kriterija vezana su za financije i fiskalnu učinkovitost (engl. *Finances and Fiscal Performance*), dug i ostale dugoročne obveze, zatim za gospodarske pokazatelje i na kraju za način upravljanja promatranom jedinicom vlasti (tablica br. 21).

Tablica 20. Pregled varijablā koje koristi agencija Fitch

Zakonodavni okvir	**Gospodarstvo**
Struktura i fleksibilnost prihoda i rashoda	Zaposlenost i nezaposlenost
Fiskalno izravnanje	Dohodak
Decentralizacija	Demografska struktura i kretanja
Računovodstvene politike	Porezno opterećenje
Revizija	**Financije i fiskalna učinkovitost**
Transparentnost i izvještavanje	Analiza prihoda
Kontrola i nadzor	Analiza rashoda
Dug i ostale dugoročne obveze	Operativni prihodi i rashodi
Iznos trenutnog i očekivanog duga	Financijske rezerve
Struktura duga	Likvidnost
Udio plaćenih kamata u ukupnim troškovima	**Upravljanje i administracija**
Financijski derivati	Upravljačka praksa
Potencijalne obveze	Proračunsko planiranje
Likvidnost	Političko okruženje

Izvor: Prikaz autora na temelju podataka Fitch Raiting Inc. (2016)[113].

[113] International Local and Regional Governments Rating Criteria-Outside the United States. Master criteria. https://www.fitchratings.com/research/international-public-finance/international-local-regional-governments rating-criteria-outside-united-states-effective-from-18-april-2016-to-9-april-2019-18-04-2016 (pristupljeno: 2. svibnja 2020.).

Procjenom zakonodavnog okvira, agencija Fitch ocjenjuje strukturu, fleksibilnost te utjecaj centralne vlasti na prihode i rashode.

Oslanjanje, primjerice, samo na jedan ili dva osnovna porezna prihoda (porez na dohodak ili porez na dodanu vrijednost[114]) ocjenjuje se negativno. Također, razmatra se do koje mjere lokalna i regionalna vlast može samostalno uvoditi nove poreze ili mijenjati stope postojećih poreza. Ocjenjuje se i objektivnost formule za fiskalno izravnanje, izvor sredstava koji se koristi te stupanj oslanjanja jedinica vlasti na takvu vrstu financijskog transfera. Uz to, ocjenjuju se i odgovornosti koje imaju jedinice vlasti, osobito s obzirom na globalni trend decentralizacije te s njima povezani troškovi. Agencija Fitch pozitivnim ocjenjuje uvođenje i poštivanje svih važećih računovodstvenih standarda te kontinuirano i pravovremeno provođenje revizije. Dodatno se pozitivno ocjenjuje ukoliko reviziju provode neovisni stručnjaci u odnosu na uobičajene državne revizore. Naravno, dostupnost podataka, njihova točnost i brzina objavljivanja izvještaja te njihova sveobuhvatnost (primjerice uključivanje u ukupan dug i dugovanja javnih poduzeća u većinskom vlasništvu jedinice vlasti) ocjenjuju se pozitivno prilikom razmatranja zakonodavnog okvira. Uz to, vrlo je važna kontrola, ali i nadzor koji provodi centralna vlast, ali i interna kontrola, po pitanju proračuna, ali i procesa zaduživanja.

Agencija Fitch veliki dio analiza posvećuje dugu te je uobičajeno da je veći dug obično povezan sa slabijim rejtingom. Analizira se struktura duga po pitanju dospijeća, vrste kamatne stope te valutna struktura duga. Naime, velika izloženost kratkoročnom dugu ili kratak rok do jednokratnog dospijeća glavnice predstavlja veliki rizik refinanciranja te smanjuje rejting. Uz to, velika izloženost varijabilnoj kamatnoj stopi bez adekvatnog osiguranja[115], također predstavlja povećan rizik i smanjuje rejting. Važan je, u analizi i udio plaćenih kamata u ukupnim rashodima te odnos tih kamata s kretanjem prihoda. Analiziraju se i budući investicijski planovi i njihov očekivani utjecaj na financijsku sliku jedinice vlasti. Agencija Fitch analizira i korištenje derivativnih financijskih instrumenata[116], ali i sve potencijalne obveze koje lokalna i regionalna jedinica vlasti mogu preuzeti od, primjerice, svojih poduzeća u vlasništvu i ustanova koje su osnovali. Važan segment u analizama je i likvidnost svake jedinice kojoj se dodjeljuje rejting.

[114] Kod nas je Porez na dodanu vrijednost (PDV) isključivi prihod centralne države.
[115] *Postoji nekoliko metoda ograđivanja od promjena kamatnih stopa, ali postoji i cijena takvog osiguranja od promjene kamatne stope. Neke od metoda su: ročnost, GAP menadžment, financijski „fjučers" ugovori, kamatne opcije, osiguranje kamatne stope, SWAP-ovi kamatnih stopa i sl.* (Novak, B. 2005: 137)
[116] Prema Sajteru n*ajveći se dio izvedenica odnosi na: opcije (engl. options), budućnosnice (engl. futures), zamjene (engl. swaps) i unaprijedne ugovore (engl. forward agreements)* (Sajter 2013: 6).

Fitch procjenjuje likvidnosnu poziciju temeljem podataka o gotovini i imovini koja se brzo može konvertirati u gotovinu (npr. depoziti), a isključuje udio u poduzećima jer je teško procijeniti koliko bi se brzo mogli prodati.

Kad su u pitanju gospodarski pokazatelji, agencija Fitch svoju analizu započinje industrijskom koncentracijom na nekom području, jer velika izloženost jednoj industrijskoj grani ili malom broju industrijskih sektora, smanjuje izglede za dobar kreditni rejting. Analiziraju se i trendovi u zapošljavanju te dohodak stanovništva u apsolutnim iznosima, ali i u relativnim odnosima s drugim jedinicama vlasti, državnim i međunarodnim prosjekom. Stabilan broj stanovnika može donijeti pozitivan doprinos rejtingu, jer porast broja stanovnika može povećati pritisak na investicije i ostale vidove trošenja, stoga se pomno prate i evaluiraju i trendovi vezani za stanovništvo. U konačnici, za stanovništvo je vezano i porezno opterećenje, jer smanjeno porezno opterećenje u nekoj jedinici vlasti može pozitivno utjecati na porast ekonomske aktivnosti i posljedično na porast prihoda jedinice vlasti, stoga se uspoređuje porezno opterećenje jedinice vlasti kojoj se dodjeljuje rejting s usporedivim jedinica vlasti.

Financijska pozicija i rezultati poslovanja predstavljaju četvrtu komponentu kod ocjene rejtinga lokalnih i regionalnih jedinica. Strukturni deficit (engl. *structural deficit*) predstavlja povećan rizik te stoga donosi negativne ocjene kod izrade rejtinga. Procjenjuju se izvori financiranja, njihova promjenjivost, raznovrsnost, dinamika prikupljanja i predvidivost. Jedinice vlasti koje mogu značajno držati pod kontrolom svoje izvore financiranja te imaju ovlasti da samostalno prilagođavaju porezne stope mogu očekivati pozitivniju ocjenu rejting agencije. Detaljno se analiziraju i trendovi u trošenju sredstava, te fleksibilnost jedinice vlasti u prilagodbama pojedinih vrsta troškova izvorima financiranja. Primjerice, udio troškova osoblja u ukupnim troškovima jedan je od važnijih pokazatelja koji govori o fleksibilnosti troškovne strane proračuna. Operativni rezultat važan je segment procjene financijske pozicije jedinice vlasti te se on koristi u usporedni s operativnim prihodom kako bi se dobila operativna marža. Snažna operativna marža predstavlja pozitivan temelj kod ocjenjivanja, jer govori o fleksibilnosti jedinice vlasti. Agencija Fitch pozitivnim ocjenjuje dobro upravljanje vlastitim sredstvima te brigu o likvidnosti. Uz to, pozitivnim se ocjenjuje i održavanje rezervi likvidnosti koje u određenim trenutcima mogu pozitivno utjecati na financijsku fleksibilnost osobito po pitanju servisiranja duga.

Upravljanje i administracija mogu pozitivno i negativno utjecati na dodjelu konačnog rejtinga. Naime, agencija Fitch pozitivnim ocjenjuje implementaciju i pridržavanje kvalitetnih procedura po pitanju planiranja i izvršavanja proračuna, zaduživanja i financijskih operacija. Također, pozitivnim se ocjenjuje i politička stabilnost u jedinici vlasti, a ključan je element za ocjenu rejtinga efikasnost u donošenju odluka vezanih za javne usluge i trošenje, zatim efikasnost u prilagodbi na gospodarske promjene te prilagodbi na institucionalne reforme.

Nakon što, primjenom metodologije, odrede razinu rizika agencije dodjeljuju toj razini rizika oznaku. Ta se oznaka, odnosno rejting, sastoji od slova, brojki i matematičkih simbola, a u tablici br. 21 prikazane su skale analiziranih, najvećih rejting agencija.

Tablica 21. Pregled skala velikih kreditnih rejting agencija (ocjene dugoročnih obveza)

S&P	Fitch	Moody's	Opis
Investicijski rejting			
AAA	AAA	Aaa	Najviša kreditna kvaliteta
AA+	AA+	Aa1	Visoka kreditna kvaliteta
AA	AA	Aa2	
AA-	AA-	Aa3	
A+	A+	A1	Iznadprosječna kreditna kvaliteta
A	A	A2	
A-	A-	A3	
BBB+	BBB+	Baa1	Adekvatna kreditna kvaliteta
BBB	BBB	Baa2	
BBB-	BBB-	Baa3	
Špekulativni rejting			
BB+	BB+	Ba1	Ispunjavanje obveza nije sigurno
BB	BB	Ba2	
BB-	BB-	Ba3	
B+	B+	B1	Rizik od neispunjavanja obveza u budućnosti
B	B	B2	
B-	B-	B3	
CCC+	CCC+	Caa1	Velika vjerojatnost neispunjavanja obveza
CCC	CCC	Caa2	
CCC-	CCC-	Caa3	
CC	CC	Ca	
C	C	C	
D	DDD		Neispunjavanje obveza
	DD		
	D		

Izvor: Prikaz autora na temelju podataka Hrvatske narodne banke (HNB)[117]

Rejting može biti vezan za dug u domaćoj i stranoj valuti te može biti kratkoročni (do 13 mjeseci[118]) i dugoročni. U tablici br. 22 je vidljivo da su skale dugoročnog duga agencija S&P

[117] https://www.hnb.hr/temeljne-funkcije/medunarodni-odnosi/kreditni-rejting (pristupljeno: 8. studenoga 2020.).
[118] Prema agenciji Fitch

i Fitch gotovo identične, dok agencija Moody's ima nešto drugačiju skalu, ali sve tri agencije s tri slova a (AAA ili Aaa) označavaju najviši rejting, odnosno najvišu kreditnu kvalitetu te rejtinge dijele u dvije osnovne kategorije: investicijski rejting i špekulativni rejting. Agencije S&P i Fitch, osim rejtinga koji označava najvišu kreditnu kvalitetu, preostale rejtinge dijele u kategorije u kojima matematički simbol plus (+) označava najviši rejting u kategoriji, a matematički simbol minus (-) najniži rejting u kategoriji te ih raspoređuje u rasponu od AAA do D. Agencija Moody's slovnim oznakama dodjeljuje brojeve, pa tako brojem jedan označava najviši rejting u kategoriji, a brojem 3 najniži. Agencija Moody's koristi raspon od Aaa do C. Ovim slovnim oznakama, agencije dodaju i izglede (engl. *outlook*) za dugoročno zaduživanje koji mogu biti pozitivni, stabilni ili negativni ovisno o očekivanju agencija u kojem bi se smjeru mogao kretati budući rejting. Bach (2014) ističe da unatoč određenim metodološkim razlikama, postoji velika korelacija između rejtinga kojeg dodjeljuju velike rejting agencije (tablica br. 22).

Tablica 22. Usporedba dodijeljenih rejtinga velikih rejting agencija zemljama članicama EU, Velikoj Britaniji i kandidatima za članstvo u EU (dugoročni dug u stranoj valuti)

Naziv države	Moody's	S&P	Fitch	Naziv države	Moody's	S&P	Fitch
Belgija	Aa3	AA	AA-	Estonija	A1	AA-	AA-
Francuska	Aa2	AA	AA	Letonija	A3	A+	A-
Italija	Baa3	BBB	BBB-	Litva	A3	A+	A
Luksemburg	Aaa	AAA	AAA	Madžarska*	Baa3	BBB	BBB
Nizozemska	Aaa	AAA	AAA	Malta	A2	A-	A+
Njemačka	Aaa	AAA	AAA	Poljska*	A2	A-	A-
Danska*	Aaa	AAA	AAA	Slovačka	A2	A+	A+
Irska	A2	AA-	A+	Slovenija	Baa1	AA-	A
Grčka	B1	BB-	BB	Bugarska*	Baa2	BBB	BBB
Portugal	Baa3	BBB	BBB	Rumunjska*	Baa3	BBB-	BBB-
Španjolska	Baa1	A	A-	**Hrvatska***	**Ba2**	**BBB-**	**BBB-**
Austrija	Aa1	AA+	AA+	Turska***	B1	B+	BB-
Finska	Aa1	AA+	AA+	Sjev. Makedonija***	–	BB-	BB+
Švedska*	Aaa	AAA	AAA	Crna Gora***	B1	B+	–
Češka*	Aa3	AA-	AA-	Srbija***	Ba3	BB+	BB+
Cipar	Ba2	BBB-	BBB-	Albanija***	B1	B+	–
V. Britanija**	Aa2	AA	AA-				

Izvor: Prikaz autora na temelju podataka Hrvatske narodne banke (HNB)[119]
* Zemlje članice izvan europodručja; ** Izašla iz Europske unije 31. 1. 2020.; *** Zemlje kandidati za članstvo u EU.

[119]https://www.hnb.hr/documents/20182/1131189/h-zemlje-clanice-eu-i-kandidati.pdf/dc91150c-cf59-4687-83f2-d08b2d3bfa00 (pristupljeno: 3. svibnja 2020.).

U tablici br. 22 označeno je 11 zemalja koje, sukladno usporednoj skali iz prethodne tablice, imaju jednaku razinu rizika dodijeljenu od strane sve tri velike rejting agencije. Zanimljivo je primijetiti da su agencije jednoglasne kod dodijele najvišeg kreditnog rejtinga. Za sve ostale prikazane zemlje postoji u pravilu razlika u jednoj ili dvije razine rejtinga uz izuzetak Slovenije koja ima nešto veći raspon. Važno je napomenuti da je analizom 1.398 dodijeljenih rejtinga u 1990. godini od strane Moody's i Standard & Poor's utvrđeno da je u 64 % slučajeva dodijeljen isti rejting, u 16 % slučajeva agencija Moody's dodijelila je viši rejting, dok je pak u 20 % slučajeva viši rejting dodijelila agencija Standard & Poor's, a korelacija između navedenih agencija iznosila je visokih 0,97[120] (Cantor, Packer 1995).

Prihodi rejting agencija prvenstveno dolaze od naknada za izdavanje rejtinga koje plaćaju izdavatelji i oni obično čine između 80 % i 90 % ukupnih prihoda rejtinga agencija. U pravilu se radi o jednokratnoj naknadi koja je izražena u postotku (primjerice 5 baznih poena u odnosu na iznos glavnice duga) te o godišnjoj naknadi za nadzor koja se naplaćuje svake godine do dospijeća glavnice. Bitno je naglasiti da *Moody's i Standard & Poor's uobičajeno naplaćuju naknadu i za rejtinge koje bi svakako sami izdali (najčešće su to vodeća svjetska poduzeća), jer poduzeća žele priliku da se sami prezentiraju rejting agencijama u 'najboljem svjetlu*' (Cantor i Packer 1995: 15). Preostali prihodi dolaze od različitih konzultantskih usluga, odnosno kroz različite istraživačke i analitičke ekspertize i istraživanja. Glavne slabosti rejting agencija identificirane na Forumu financijske stabilnosti (engl. *Financial Stability Forum*) [121], a vezane za strukturirane kreditne proizvode (engl. *structured credit products*) su:

1. *slabosti u rejting modelima i metodologijama*
2. *neadekvatna kontrola kvalitete kolaterala kojima su osigurane vrijednosnice za koje je izdan rejting*
3. *nedovoljna transparentnost vezana za pretpostavke, kriterije i metodologije pri davanju rejtinga*
4. *nedovoljno davanje informacija o značenju i karakteristikama rizika rejtinga strukturiranog financiranja (engl. structured finance ratings)*
5. *nedovoljna pozornost usmjerena na sukob interesa u procesu izdavanja rejtinga*.

[120] *Koeficijent korelacije najčešća je korištena mjera za opisivanje povezanosti varijabla. Njome se opisuje smjer i jakost povezanosti promatranih varijabla koje se nalaze u linearnom odnosu* (Horvat, J.; Mijoč, J. 2018: 478).
[121] Report of the Financial Stability Forum on Enhancing Market and Institutional Resilience. https://www.fsb.org/wp-content/uploads/r_0804.pdf (pristupljeno: 10. svibnja 2020.).

Dodatno, brzina promjene rejtinga i upozorenja investitora na mogući bankrot pokazala se neadekvatnom. Primjerice, obveznice Enrona do pet dana prije proglašenja bankrota imale su investicijski rejting sve tri velike rejting agencije, a na dan bankrota Lehman Brothersa isti su rejting imali i njihovi komercijalni papiri. *Rejting agencije od toga se ograđuju na način da kažu da one ne nude podatke o trenutnoj procjeni ('iz minute u minutu') nego oni ocjenjuju dugoročnu perspektivu, a manji broj promjena rejtinga omogućava agencijama poslovanje s manjim brojem djelatnika* (White 2010: 2018-2019).

4.1.3. Kretanje kreditnog rejtinga Republike Hrvatske i Grada Zagreba

Države traže kreditni rejting kako bi sebi, ali i poduzećima sa svog područja, olakšale pristup međunarodnim tržištima kapitala. Naime, *institucionalni investitori nisu pretjerano zainteresirani kupovati obveznice od rizičnih izdavatelja s tržišta u razvoju, ukoliko nemaju razmjeran rejting pouzdane rejting agencije* (Langohr i Langohr 2008: 133). *Kreditni se rejting neke države može shvatiti i kao ulazna vrata za stvaranje dobre investicijske klime i pokazatelj koji će svaki institucionalni investitor provjeriti pri donošenju odluke o investiranju u neku zemlju* (Bajo i Penava 2012: 55). Unatoč činjenici da rejting agencije koriste velik broj kriterija da bi dodijelile rejting nekoj državi, ti su rejtinzi snažno povezani s makroekonomskim pokazateljima. Cantor i Packer (1996: 48) izračunali su da *90 % oscilacija može biti objašnjeno korištenjem šest ključnih pokazatelja, a to su:*

1. *BDP po stanovniku*
2. *rast realnog BDP-a*
3. *stopa inflacije*
4. *vanjski dug*
5. *razina gospodarske razvijenosti*
6. *povijest nemogućnosti plaćanja (engl. default history)*.

Rejting države obično predstavlja gornju granicu rejtinga gradova iz te države budući da postoji snažna povezanost svih razina vlasti, isto tako i zbog značajne kontrole koje centralna vlast u okviru formativnih nadležnosti ima nad lokalnim jedinicama te mogućnostima državnih intervencija[122]. Naravno, postoji uvijek mogućnost da neke lokalne jedinice imaju i bolji rejting od rejtinga države. Radi se primarno o gospodarstvima u kojima je lokalnim jedinicama dana

[122] https://www.fitchratings.com/research/international-public-finance/international-local-regional-governments-rating-criteria-outside-united-states-effective-from-18-april-2016-to-9-april-2019-18-04-2016 (pristupljeno: 2. svibnja 2020.).

velika autonomija za reguliranje poreza na svom području. Dodatno, riječ je i o lokalnim jedinicama koje imaju slobodan pristup izvorima financiranja te bolju ocjenu kreditnog profila.

Kreditni rejting država sastoji se od velikog broja kvantitativnih i kvalitativnih varijabli. *Pri dodjeli kreditnog rejtinga državama agencije, između ostalog, uzimaju u obzir sljedeće parametre*[123]*:*

1. *prihode i gospodarsku strukturu*
2. *očekivani gospodarski rast*
3. *monetarnu i fiskalnu fleksibilnost*
4. *vanjsku likvidnost*
5. *političke rizike*
6. *zaduženost javnog i privatnog sektora*
7. *zaduženost državnih tvrtki* (HNB).

Gospodarski najsnažnije i najrazvijenije zemlje Europske unije, zemlje su i s najvišim kreditnim rejtingom (tablica br. 23). Kao što je već istaknuto, kod dodjele najvišeg rejtinga (AAA ili Aaa) postoji konsenzus najvećih rejting agencija odnosno Njemačka, Nizozemska, Danska, Švedska i Luksemburg, zemlje su koje imaju najbolji kreditni rejting. Važno je istaknuti kako Danska i Švedska nisu dio europodručja, ali to nije utjecalo na njihov kreditni rejting. Vrlo visok kreditni rejting imaju i Austrija, Finska te bivša članica unije, Velika Britanija.

Dodatno, važno je istaknuti i zemlje nastale raspadom Sovjetskog saveza koje su od tada prošle kvalitetne procese tranzicija svojih gospodarstava te danas imaju visoku (Estonija), odnosno iznadprosječnu kreditnu kvalitetu (Letonija i Litva).

Visković i Katavić (2017) ističu da članstvo u Europskoj monetarnoj uniji pozitivno utječe na kretanje rejtinga. Na samom dnu investicijskog razreda su Rumunjska, Republika Hrvatska i Cipar, dok je Grčka jedina zemlja članica Europske Unije sa špekulativnom razinom kreditnog rejtinga. Od zemalja kandidata za članstvo u Europskoj uniji, najviši rejting ima Srbija, a na samom su začelju Turska, Crna Gora i Albanija.

[123] Hrvatska narodna banka (HNB), https://www.hnb.hr/temeljne-funkcije/medunarodni-odnosi/kreditni-rejting (pristupljeno: 8. studenoga 2020.).

Tablica 23. Usporedni prikaz zemalja članica Europske Unije, Velike Britanije i zemalja kandidata za članstvo po rejting kategorijama prema agenciji S&P (rejting za dugoročno zaduživanje u stranoj valuti)

S&P rejting	Naziv države				
AAA	Luksemburg	Nizozemska	Njemačka	Danska*	Švedska*
AA+	Austrija	Finska	Velika Britanija**		
AA	Belgija	Francuska			
AA-	Irska	Češka*	Estonija	Slovenija	
A+	Slovačka	Letonija	Litva		
A	Španjolska				
A-	Malta	Poljska*			
BBB+					
BBB	Italija	Portugal	Madžarska*	Bugarska*	
BBB-	Cipar	Rumunjska*	Hrvatska*		
BB+	Srbija***				
BB					
BB-	Grčka	Sjeverna Makedonija***			
B+	Turska***	Crna Gora***	Albanija***		

Izvor: Prikaz autora na temelju podataka Hrvatske narodne banke (HNB)[124];
* Zemlje članice izvan europodručja
** Izašla iz Europske unije 31. siječnja 2020.
*** Zemlje kandidati za članstvo u EU

Velike rejting agencije 1997. godine prvi su put dodijelile kreditni rejting Republici Hrvatskoj te se od tada sve do 2012. godine rejting države nalazio u investicijskom razredu. Loša gospodarska kretanja i potreba za provođenjem strukturnih reformu, zadržale su kreditni rejting Republike Hrvatske u špekulativnom razredu sljedećih nekoliko godina. U 2018. godini agencije Standard & Poors (grafikon br. 3) i Fitch povećavaju svoj rejting Republici Hrvatskoj, da bi u 2019. godini njihova ocjena *vratila* državni rejting u investicijski razred. Agencija Moody's nije povećavala svoju ocjenu Republike Hrvatske u posljednjih nekoliko godine, te je državni rejting prema njima i dalje dvije razine ispod investicijskog razreda (Ba2).

Agencija Standard & Poor's, prilikom zadnjeg povećanja kreditnog rejtinga u svibnju 2019. godine[125], navodi da bi nastavak rasta kreditnog rejtinga uslijedio, ukoliko bi se trend gospodarskog rasta Republike Hrvatske nastavio i pokazao otpornim na usporavanje europskog gospodarstva te samim time povećala konvergencija s prosječnim razinama prihoda na razini

[124]https://www.hnb.hr/documents/20182/1131189/h-zemlje-clanice-eu-i-kandidati.pdf/dc91150c-cf59-4687-83f2-d08b2d3bfa00 (pristupljeno: 3. svibnja 2020.).
[125] https://www.standardandpoors.com/en_US/web/guest/article/-/view/type/HTML/id/2185192#ContactInfo (pristupljeno: 19. srpnja 2020.).

Europske unije. Dodatno, smanjenje javnog duga brže od predviđanja Agencije može pozitivno utjecati na kretanje rejtinga.

Grafikon 3. Kretanje rejtinga Republike Hrvatske i Grada Zagreba od 1997. do 2020. godine prema podatcima agencije S&P (dugoročno zaduživanje u stranoj valuti)

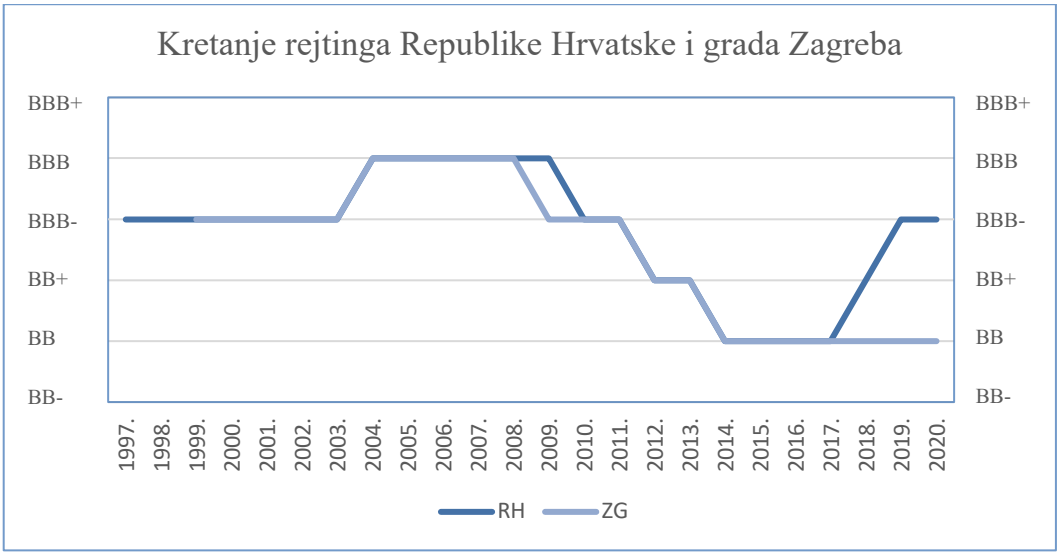

Izvor: Prikaz autora na temelju podataka agencije Standard & Poor's (S&P)[126]

Povezanost rejtinga države i gradova već je istaknuta, pri čemu treba naglasiti postojanje svojevrsnog pravila po kojem rejting države predstavlja gornju granicu rejtinga svih gradova u istoj državi. Takvo pravilo vidljivo je i kod međusobnog odnosa rejtinga Republike Hrvatske i rejtinga Grada Zagreba, koji je jedini grad u Republici Hrvatskoj kojem je dodijeljen rejting od strane velikih rejting agencija[127]. Naime, u studenom 2012. godine Gradu Zagrebu je, od agencije Standard & Poor's, potvrđen rejting BBB-, što je i dalje rejting investicijskog razreda. Manje od mjesec dana kasnije, u prosincu iste godine, agencija snižava kreditni rejting Republike Hrvatske na BB+ te istovremeno snižava i rejting Grada Zagreba na istu razinu. Naknadno je, 2014. godine, rejting dodatno smanjen na razinu BB. Automatizam kojim se agencija vodila prilikom snižavanja rejting nije primijenjen prilikom rasta rejtinga države, te je nakon dvogodišnjeg rasta rejtinga države, rejting Grada Zagreba i dalje ostao dvije razine ispod investicijskog.

[126] https:// www.standardandpoors.com/en_US/web/guest/ratings/entity/-/org-details/sectorCode/ GOVS/ entityId/336925 (pristupljeno: 8. studenoga 2020.).
[127] Glavni razlog leži u činjenici da se radi o glavnom gradu Republike Hrvatske.

Ista agencija dodjeljuje i kreditni rejting Zagrebačkom holdingu[128], trgovačkom društvu u vlasništvu Grada Zagreba, te je rejting navedenog društva bio 2016. i 2017. godine jednu razinu ispod razine Grada Zagreba (BB-), a sljedeće dvije godine čak dvije razine ispod kreditnog rejtinga vlasnika (B+). Osim o rejtingu države, Bajo (2008) ističe da buduće financiranje Grada Zagreba, zbog značaja i veličine Zagrebačkog holdinga, uvelike ovisi i o stabilnosti financiranja Zagrebačkog holdinga.

Budući da rejting agencije imaju različitu metodologiju koji primjenjuju prilikom ocjenjivanja gradova, na grafikonu br. 4 prikazana su kretanja rejtinga Grada Zagreba od strane dvije velike rejting agencije.

Grafikon 4. Kretanje rejtinga Grada Zagreba od 1999. do 2020. godine prema podatcima agencija Moody's i S&P (dugoročno zaduživanje u stranoj valuti)

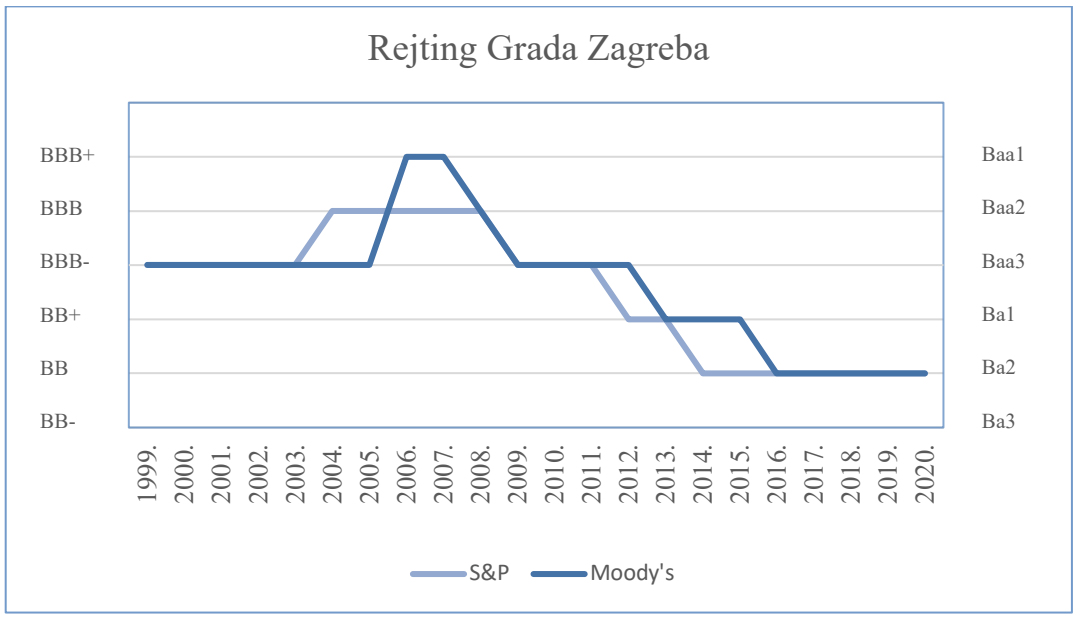

Izvor: Prikaz autora na temelju podataka agencija Moody's i Standard & Poor's[129]

U promatranom periodu od 1999. godine do početka 2020. godine, 15 godina je Grad Zagreb imao istovjetnu razinu rejtinga od strane obje promatrane rejting agencije. Zamjetno je da agencija Standard & Poor's u nekoliko navrata *brže* reagirala kad su u pitanju promjene

[128] *Zagrebački holding d. o. o. osnovan je 2007. godine i u 100-postotnom je vlasništvu Grada Zagreba. Sastoji se od 14 podružnica koje obavljaju djelatnosti nekadašnjih gradskih poduzeća, Zagrebački holding d. o. o. vlasnik je i 8 trgovačkih društava te jedne ustanove, a ukupni broj zaposlenih je 7 877* (Zagrebački holding d. o. o.). https://www.zgh.hr/o-nama/profil/13 (pristupljeno: 8. studenoga 2020.).

[129] https://www.moodys.com/credit-ratings/Zagreb-City-of-credit-rating-600049426 i https://www.standardandpoors.com/en_US/web/guest/ratings/entity/-/org-details/sectorCode/GOVS/entityId/336925 (pristupljeno: 8. studenoga 2020.).

kreditnog rejtinga. Primjerice 2009. godine navedena agencija ističe da je razlog snižavanja rejtinga povećano zaduživanje dinamikom većom od očekivanja te slabija pozicija likvidnosti u situaciji gospodarske krize. Razni autori, a među njima i Bajo i Primorac (2010: 27) navode nužnost uvođenja ocjene kreditne sposobnosti kroz sustav kreditnog rejtinga, za sve lokalne jedinice, kako bi se poboljšala kontrola pridržavanja proračunskih ograničenja, ali što je možda i važnije, pravilnije određivali prioriteti u odobravanju zaduživanja lokalnih jedinica.

4.1.4. Kreditni rejting i transparentnost

Sve velike rejting agencije u svom procesu ocjenjivanja značajnu pažnju pridaju i transparentnosti. Jednim se dijelom ona ocjenjuje u fazi procjene zakonodavnog okvira, a drugim dijelom kad je u pitanju procjena upravljanja.

Agencija Fitch naglašava da postoje države u kojima su financijski podatci lokalnih jedinica dostupni odmah po završetku obračunskog razdoblja (najčešće godine) na njihovim stranicama ili stranicama resornog ministarstva. Transparentnost u iskazivanju podataka investitorima je vrlo bitna. Isto se odnosi i na informacije o vlastitim potencijalnim obvezama (primjerice već spomenuti sudski spor slavonskih gradova i poduzeća Strabag i Saubermacher) te na financijske podatke javnih poduzeća u njihovom vlasništvu. Javna su poduzeća bitna, jer njihovo financijsko posrtanje može odmah utjecati i na lokalnu jedinicu koja je vlasnik poduzeća.

Dakle, ako su podatci pravodobni i javno dostupni, ako su detaljni i jasni uz kvalitetna obrazloženja kako postignutih rezultata, tako i budućih očekivanja, onda ocjena koju daju rejting agencije kvalitetnije prezentira njihovo financijsko stanje te za investitore predstavlja manje rizično ulaganje.

Transparentnost nije isključivo vezana za financijske podatke. Investitore i rejting agencije zanima transparentnost i po pitanju kontrole svih podataka i procesa te transparentnost u svim aspektima upravljanja. Veliki se značaj kod transparentnosti pridaje neovisnim ocjenama revizora, gdje se državna revizija ne smatra neovisnom i kao takva nema dovoljno učinkovite mehanizme.

4.2. Kredit *scoring* kao dio kreditnog rejtinga

Kreditne rejting agencije koriste kombinaciju kvantitativnih i kvalitativnih pokazatelja prilikom izračuna kreditnog rejtinga. Vrlo slične modele koriste i banke, ali i institucionalni investitori

(investicijski fondovi, mirovinski fondovi i sl.). Kvantitativni dio njihovih izračuna predstavlja kredit *scoring*.

Jednostavna definicija kredit *scoringa* kaže da se *radi o upotrebi statističkih modela kako bi se relevantni podatci transformirali u brojčane mjere i time odredila odluka o davanju kredita* (Anderson 2007: 6). Navedeni statistički modeli su prediktivni i osnovna im je svrha podijeliti slučajeve na one s niskom razinom rizika i one s visokom razinom rizika te tako ih razdvojiti na one *loše* za koje postoji velika vjerojatnost da neće na vrijeme moći plaćati svoje obveze od onih *dobrih* za koje postoji mala vjerojatnost od takvih poteškoća u vidu ispunjavanja financijskih obveza. Najčešće se za takve modele koriste različiti regresijski modeli odnosno *najčešće korišteni scoring modeli su: linearna regresija, logistička regresija (logit), probit model i analiza višestruke diskriminacije – MDA* (engl. *multiple discriminant analysis*) (De Servigny, Renault 2004: 75). Nije neuobičajeno da se kod testiranja modela uspoređuju rezultati različitih statističkih metoda kako bi se utvrdio pristup s najvećom prediktivnom snagom. Primjerice, Altman i Sabato (2007) koristili su, u svojem istraživanju malih i srednjih poduzeća, više modela odnosno prvo logističku regresiju te su nakon toga svoj model testirali i putem analize višestruke diskriminacije. Naravno, osim navedenih modela, postoje i noviji, napredniji modeli koji koriste neparametarske tehnike. *Mnoge takve tehnike dolaze iz polja machine learning metoda, kao što su: neuronske mreže, genski algoritmi i algoritam k-najbližih susjeda* (Anderson 2007: 58).

Scoring modeli započeli su još 30-ih godina prošlog stoljeća, popularnost im je porasla krajem 70-ih godina kad je Altman predstavio *Z-score*. Misao vodilja od tada pa sve do danas ostala je ista: s malim brojem ključnih financijskih varijablā, putem jednostavnog modela, razdvojiti dobre i manje rizične od onih loših i više rizičnih.

Povijesno gledajući, ubrzani razvoj kvantitativnih metoda prilikom odobravanja kredita događao se paralelno s razvojem modernih tehnologija, ali i s usmjerenošću na brže odobravanje kredita uz veću vjerojatnost povrata sredstava. Naime, scoring modeli u bankarstvu, tijekom godina, gotovo su u potpunosti zamijenili ljudski faktor te takvi automatizirani sustavi odobravaju kredite stanovništvu i malim poduzećima.

Osnovni razlog leži u činjenici da je njihovo financijsko ponašanje moguće jednostavnije predvidjeti, odnosno rizik nemogućnosti plaćanja obveza po njihovom dospijeću lakše je kvantificirati i ukoliko se nalazi u prihvatljivim okvirima, kredit se realizira. *Najčešće se ovi modeli procjene kreditnog rizika temelje na povijesnim podatcima o prošloj urednosti dužnika*

pri vraćanju prethodnih kredita (Sajter 2017: 105). Primjerice, kod malih se poduzeća dodatno ocjenjuje iskustvo u poslu, vlasnička struktura i omjer vlastitog ulaganja u odnosu na zatražena kreditna sredstva (tablica br. 24).

Kad su u pitanju velika poduzeća iz perspektive banaka, ali i dodjela sveobuhvatnih rejting ocjena velikih rejting agencija, i dalje se *scoring* modeli koriste kao neizostavan dio kreditne analize, ali prilikom dodjele konačne ocjene uključuju se i kvalitativne informacije.

Tablica 24. *Scorecard* korišten pri ocjenjivanju poduzeća

Struktura posla	Jedan vlasnik	Partnerstvo	Kompanija		
	7	4	0		
Dužina odnosa s tom financijskom institucijom	0 do 1 godina	1 do 2 godine	3 do 5 godina	Više od 6 godina	
	0	2	8	10	
Godišnja promjena u profitu	Gubitak prethodne godine ili nepoznato	Dobitak u prethodnoj godini	Rast profita iz godine u godinu		
	0	5	10		
Kredit/osobno ulaganje	Bez osobnog ulaganja	15 do 50 %	51 do 100 %	101 do 250 %	Preko 250 %
	0	8	6	3	1
Iskustvo u poslu	0 do 2 godine	3 do 4 godine	5 do 7 godina	8 i više godina	
	0	2	7	9	

Izvor: Nataša Šarlija. 2002. *Modeli kreditnog rizika u ocjenjivanju kreditne sposobnosti malih poduzeća.* Doktorska disertacija. Sveučilište u Zagrebu. Ekonomski fakultet u Zagrebu. 83. str.

U praksi, svi *scoring* modeli, funkcioniraju na sličan način. U određeni informacijski sustav unose se kvantitativni podatci, a najčešće je riječ o financijskim podatcima o poslovanju, kroz određeni, prethodni vremenski period. Što je promatrani, vremenski period dulji, manji je utjecaj cikličkih gospodarskih kretanja. Dodatno, često se u analize uključuju i planski podatci, odnosno podatci za predstojeći vremenski period (tri do pet godina). Iz velike količine unesenih podataka izdvajaju se samo one varijable ili kombinacija varijablā čije su promjene povezane s promjenama u nemogućnosti vraćanja kredita. Tada se, ovisno o kompleksnosti *scorecard* modela, izdvojenim varijablama prvo dodjeljuju ocjene.

Ocjene mogu varirati na skali od 1 do 9 kao što je to primjerice kod agencije Moody's (ili na bilo kojoj drugoj brojčanoj skali) te se prema dodijeljenim ocjenama razlikuju, primjerice, gradovi s nižom ili višom razinom postojećeg duga. Razina duga razvrstava se u kategorije te svaka kategorija predstavlja jednu ocjenu. Budući da svaka, tako kreirana, varijabla nema

jednak utjecaj na konačnu ocjenu, ocjenama se dodjeljuju ponderi kojima se ističe važnost i utjecaj varijablā na konačnu ocjenu rizika (tablica br. 25).

Tablica 25. Primjer *scorecarda* korištenog od agencije Moody's za procjenu specifičnog rizika

	Ocjena	Osnovni ponder	Ukupno	Ponder varijable	Ukupno
Gospodarska snaga	1	70 %			
Gospodarska volatilnost	1	30 %			
Osnovni ekonomski pokazatelji			1,0	20 %	0,2
Zakonodavni temelj	1	50 %			
Financijska fleksibilnost	5	50 %			
Zakonodavni okvir			3,0	20 %	0,6
Operativna marža	5	12,5 %			
Kamate	3	12,5 %			
Likvidnost	1	25 %			
Iznos duga	3	25 %			
Struktura duga	3	25 %			
Financijska pozicija i dug			2,75	30 %	0,825
Upravljanje rizikom i financijama	1				
Upravljanje investicijama i dugom	1				
Transparentnost i revizija	5				
Javno upravljanje i menadžment		max	5	30 %	1,5
Ukupno					3,125
Procjena specifičnog rizika					**3**

Izvor: Prikaz autora temeljen na podatcima Moody's Investors Service (2018)[130]

U prikazanom primjeru skupine Financijska pozicija i dug te Javno upravljanje i menadžment imaju ponder 30 % te shodno tome veći utjecaj na konačnu procjenu rizika od preostale dvije skupine. Također, likvidnost te iznos i struktura duga imaju veći utjecaj na ocjenu unutar skupine Financijska pozicija i dug od operativne marže i kamata. Konačna je stoga ocjena, u prikazanom primjeru ocjena 3, rezultat složenog izračuna svih prikazanih koraka.

4.3. Okvir mjerenja čimbenika neplaćanja dospjelih obveza gradova

Znanstvenici su teoretskim i praktičnim istraživanjima, testirali različite varijable kako bi utvrdili njihov utjecaj na nemogućnost plaćanja obveza na vrijeme i u punom iznosu. U početku su se usredotočili na nemogućnost plaćanja poduzeća te je primjerice Altman (1968: 594) koristio *5 varijabli u svom modelu, od kojih su 4 varijable u nazivniku imale: ukupnu imovinu, odnosno radni kapital, zadržanu dobit, dobit prije kamata i poreza (EBIT) i prihode koji su stavljeni u omjer s ukupnom imovinom. Posljednja peta varijabla sastojala se od omjera tržišne*

[130] Regional and Local Governments. Rating methodology. 36-37 str.

vrijednosti kapitala i knjigovodstvene vrijednosti ukupnog duga. Altman je izabrao višestruku diskriminacijsku analizu (engl. *multiple discriminant analysis*), kao odgovarajuću statističku metodu za predviđanje bankrota poduzeća u SAD-u. Dodatno, nešto kasnije Ohlson (1980) je koristio uvjetnu logističku analizu (engl. *conditional logit analysis*) kako bi dokazao prediktivne sposobnosti financijskih omjera prilikom predviđanja bankrota poduzeća. Naknadno su znanstvenici svoja istraživanja, temeljena na sličnim principima, u istraživačkom kontekstu usmjerili i prema analizi gradova.

4.3.1. Suvremene znanstvene spoznaje o čimbenicima neplaćanja dospjelih obveza

Errais (2019), testirao je 40 različitih varijabli podijeljenih u tri kategorije: karakteristike (veličina lokalne jedinice ili broj stanovnika), financije (upravljanje dugom, financijska autonomija ili udio raznih vrsta prihoda u prihodima) i ponašanje (prosječna starost duga ili prosječna kamatna stopa) da bi u konačnici utvrdio da je sljedećih osam varijabli najznačajnije, a to su: stopa ostvarenog viška, koeficijent duga, koeficijent financijske autonomije, udio poreza na nekretnine u prihodima, proračunska fleksibilnost, prosječna kamatna stopa, prosječna starost duga (od trenutka zaduživanja) te prosječno vrijeme do dospijeća duga.

Navarro-Galera i suradnici (2015) testirali su 12 varijabli podijeljenih u tri grupe po četiri varijable. U prvoj su grupi demografske varijable (broj i gustoća stanovnika), socioekonomske varijable (prihod po stanovniku ili stopa nezaposlenih) te financijske varijable (struktura financiranja ili financijska autonomija). U konačnom modelu izdvojeno je šest varijabli, po dvije iz svake kategorije: gustoća stanovnika i udio ekonomski uzdržavanog stanovništva (demografija), politički predznak[131] i prihod po stanovniku (socioekonomska grupa) te struktura financiranja i omjer kratkoročnog i dugoročnog duga (financije).

Hajek i Hajkova (2009), testirali su utjecaj 11 različitih varijabli na visinu duga lokalnih jedinica te se šest varijabli pokazalo značajnima za konačni model, a to su broj stanovnika, vlastiti prihodi, veličina imovine, kategorija lokalne jedinice, regulatorne promjene te stabilnost vlasti[132].

Gregori i Marattin (2017), analizirali su podatke za osam različitih indeksa. Otplata kredita u odnosu na ukupne rashode i izdatke dio je prvog indeksa, a otplata kredita u odnosu na ukupne rashode dio drugog indeksa. Treći indeks primjerice mjeri otplate kredite u odnosu na kapitalne

[131] Konzervativan ili progresivan
[132] Mjereno putem usporedbe vlada li lokalnom jedinicom koalicijska vlast ili većinu ima samostalno jedna stanka.

rashode. Omjer ukupnih prihoda i ukupnih rashoda i izdataka, omjer ukupnih rashoda u ukupnim rashodima i izdatcima ili omjer poreznih prihoda u ukupnim rashodima i izdatcima (indeks autonomije) samo su neki od ostalih primijenjenih indeksa.

Palumbo i suradnici (2006) temeljili su postavke svoga modela na istraživanjima rejting agencije Moody's te su u model uključili sljedeće varijable: prihod po radniku, procijenjenu vrijednost imovine po stanovniku, stopu nezaposlenosti, ukupan dug po stanovniku te omjer poreznih prihoda i ukupnih rashoda.

Holian i Joffe (2013) istraživanje su temeljili na četiri fiskalna indikatora i to putem omjera rashoda za kamate i mirovine u odnosu na ukupan prihod lokalne jedinice, godišnju promjenu prihoda, omjer viška/manjka i ukupnih prihoda te omjer stanja novčanih sredstava i ukupnih rashoda i izdataka.

Gorina i suradnici (2018) testirali su 23 nezavisne varijable, a u konačni model uključili su varijable vezane za stopu nezaposlenosti, pokazatelj dugoročnih obveza, primljene pomoći te slobodna novčana sredstva.

U Hrvatskoj su Primorac i Posedel (2012) testirali 27 potencijalnih odrednica kreditnog rizika lokalnih jedinica da bi u konačnici izabrali 11 najutjecajnijih. Osim podjele uzorka na općine i gradove, testirana je primjerice povezanost lokalne i nacionalne vlasti. Omjer izvoza i BDP-a, zatim omjer broja stanovnika lokalne jedinice i ukupnog broja stanovnika Republike Hrvatske te udio nezaposlenih u broja stanovnika lokalne jedinice osnovne su socioekonomske varijable. Od financijskih varijabli korišteni su udjeli poreza na dohodak, neto operativnog rezultata, direktnog duga i neto financijske imovine u prihodima poslovanja.

Dodatno, testirana je i povezanost omjera novčanih sredstava i rashoda poslovanja te dospjelog duga i novčanih sredstava s nemogućnošću plaćanja obveza na vrijeme i u punom iznosu.

Janda i Moreira (2016) pripremili su model koji bi trebao ispravno izdvojiti gradove koji će bankrotirati i svima dodijeliti vjerojatnost bankrota. Nakon testiranja 22 varijable, utvrdili su osam varijabli koje su značajne za predviđanje između kojih su primjerice državni transferi, dug prema trećim osobama, broj stanovnika te udio prikupljenih poreznih prihoda u ukupnim prihodima.

Cohen i suradnici (2011) odabrali su šest financijskih omjera prilikom kreiranja svog modela. Omjer ukupnih obveza i ukupne imovine, vlastitih prihoda i ukupnih obveza te kratkoročnih

obveza i vlastitih prihoda varijable su vezane za bilancu lokalnih jedinica. Preostala tri omjera odnose se na udio operativnih rashoda u vlastitim prihodima, zatim na udio državnih transfera po stanovniku te vlastite prihode po stanovniku.

Kloha i suradnici (2005) kreirali su zasebnu skalu pomoću koje su rangirali gradove i predviđali fiskalne probleme. Naime, ocjenjivali su gradove putem 10 različitih faktora i za svaki faktor dodjeljivali ocjene. Neki od faktora su primjerice rast broja stanovnika, neto operativni rezultat, dugoročni operativni manjak te visina dugoročnog duga u odnosu na porezne prihode. Loši pojedinačni rezultati svake pojedine kategorije donosili su više skupne ocjene. Temeljem prikupljenih rezultata, a budući da su iste gradove pratili tijekom višegodišnjeg perioda, razvili su dodatnu skalu kojom su razvrstavali gradove u nekoliko kategorija od kojih su najbolji gradovi svrstani u kategoriju fiskalno *zdravih*, dok su ostalim gradovima izdali različite vrste fiskalnih upozorenja.

Kreditni rejting i vremenski period od izdavanja, primjerice, obveznice do njezinog dospijeća utječu na nemogućnost plaćanja obveza. *Povećana vjerojatnost nemogućnosti plaćanja raste s produljenjem vremenskog horizonta i promjenom rejting kategorije, ali i dalje ostaje negativna korelacija između rejtinga i nemogućnosti plaćanja* (Cantor i Packer 1995: 20). Agencija Moody's objavila je analizu kretanja prosječne stope *defaulta* (grafikon br. 5) za lokalne jedinice provedenu na podatcima za razdoblje od 25 godina.

Grafikon 5. Kretanje prosječne kumulirane stope *defaulta* izdavatelja po rejting kategorijama za lokalne jedinice u periodu 1983. do 30.6.2018. godine od strane agencije Moody's

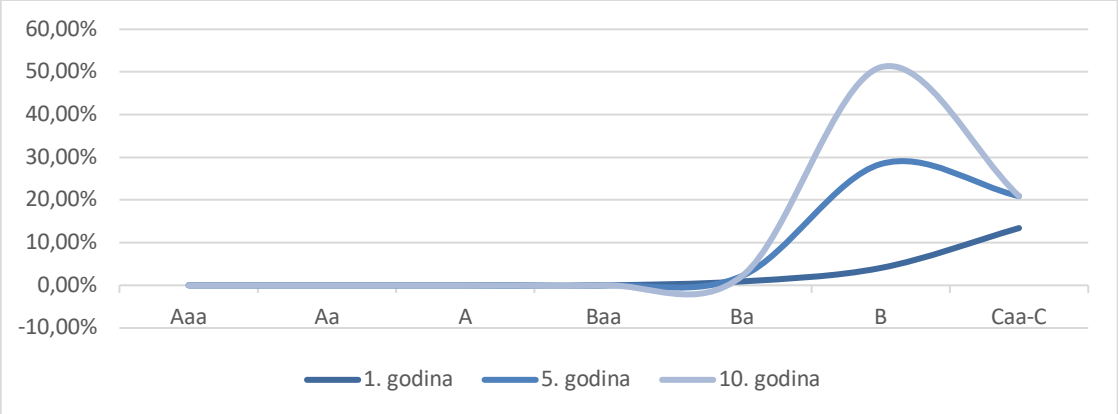

Izvor: Prikaz autora na temelju podataka Moody's Investor Service (2019)[133]

[133] *Sub-Sovereign Default and Recovery Rates. 1983-2018H1*

Izdavatelji koji su prilikom izdanja obveznica imali investicijski rejting, nisu došli u situaciju nemogućnosti plaćanja (Aaa do Baa). Kod izdavatelja sa špekulativnim rejtingom, svaka niža razina rejtinga donijela je veću vjerojatnost nemogućnosti plaćanja. Izdavatelji iz najviše špekulativne kategorije (kategorija Ba) imali su u prvoj godini vjerojatnost nemogućnosti plaćanja 0,92 %, izdavatelji iz srednje špekulativne kategorije (kategorija B) 4,06 %, a iz najniže, zadnje špekulativne kategorije 13,41 %. Slična je situacija s drugim promatranim godinama. Gledajući kroz godine prosječno kretanje nemogućnosti plaćanja kod izdavatelja sa špekulativnim rejtingom, taj postotak odnosno vjerojatnost kontinuirano raste s protekom godina od izdavanja. Naime, u prvoj godini ta je vjerojatnost 3,19 %, u petoj godini 12,56 %, a u desetoj godini ona iznosi 23,23 %.

4.3.2. Čimbenici koji utječu na nemogućnost plaćanja obveza u Republici Hrvatskoj

Stein (2007: 107) ističe da je korisno identificirati najsnažniji dostupni model i onda ga kalibrirati. Izborom snažnog modela povećava se vjerojatnost da će izabrani model imati prihvatljive karakteristike. Stoga analizirajući praksu najvećih rejting agencija i literaturu, te usklađujući isto sa zakonodavnim uređenjem lokalnih jedinica u Republici Hrvatskoj, čimbenici koji utječu na kreditni rejting, odnosno na vjerojatnost neplaćanja mogu se podijeliti na: zakonodavni okvir, financije i proračun, likvidnost i dug te stanovništvo (socioekonomski čimbenici).

a) Zakonodavni okvir

Zakonodavni se okvir u pravilu kvalitativno ocjenjuje i u najvećoj se mjeri ocjenjuju fiskalna fleksibilnost i adekvatnost fiskalne snage za dane odgovornosti. Navedeni je okvir jednak za sve lokalne jedinice u Republici Hrvatskoj, ali primjena zakonodavnih odredbi (primjerice o uvođenju nekog od lokalnih poreza) može značajno varirati između lokalnih jedinica i utjecati na vjerojatnost neplaćanja. Osnovna struktura, fleksibilnost i uravnoteženost prihodovne i rashodovne strane proračuna, način obavljanja proračunskog nadzora, računovodstvene politike i način izvještavanja načelno su jednaki je za sve lokalne jedinice. Fiskalna fleksibilnost lokalnih jedinica je dosta niska, jer je vrlo uzak raspon prihoda koje lokalne jedinice mogu samostalno uvesti, te se sve uglavnom oslanjaju na prihod od poreza na dohodak. Kad su u pitanju gradovi, najveći prihod koji mogu uvesti je prirez porezu na dohodak. Razlike između lokalnih jedinica u najvećoj mjeri postoje u pogledu primjene izračuna i podjele sredstava fiskalnog izravnanja te u razini transparentnosti.

b) Financije i proračun

U sklopu financija i proračuna, čimbenici koji mogu utjecati na nemogućnost plaćanja lokalnih jedinica vezani su za ostvarenja ukupnih prihoda i rashoda odnosno pojedinih stavki prihodovne i rashodovne strane proračuna odnosno za promjenjivost novčanog tijeka. Na prihodovnoj su strani u Republici Hrvatskoj to, primjerice, osnovni poslovni prihodi lokalne jedinice odnosno to se prvenstveno odnosi na prihode od poreza na dohodak, čije negativne oscilacije mogu značajno narušiti mogućnost pravovremenog plaćanja obveza. Slična je situacija i s pomoći koja se slijeva u lokalne proračune. Također, struktura prihodovne i rashodovne strane (odnos pojedinih stavki prihoda/rashoda prvenstveno s ukupnim prihodima) mogu se pokazati presudnima kod očuvanja stabilnosti u situaciji pada proračunskih prihoda ili naglog rasta troškova. Fleksibilnost rashodovne strane proračuna ocrtava se najvećim dijelom u činjenici koliko je visok udio troškova osoblja u ukupnim troškovima. Kvalitetno upravljanje investicijama u smislu financiranja i same provedbe projekta može omogućiti stabilno poslovanje bez dospjelih, neplaćenih obveza. Jednaka stabilnost postiže se preveniranjem i ostalih rizika poslovanja (npr. pravodobna naplata potraživanja) te jednakovrijednom pripremom za negativne scenarije (npr. negativne sudske presude).

c) Likvidnost i dug

Prosječno stanje na računu lokalne jedinice treba biti razmjerno usklađeno s tekućim potrebama proračunskih rashoda. Oscilacije tijekom proračunske godine znaju biti vrlo izražene jer poprilična linearnost prikupljenih prihoda tijekom godine (ponajprije kad su u pitanju porezni prihodi, te prihodi od komunalne naknade) u koliziji je s dijelom nelinearne proračunske potrošnje. Loše upravljanje financijskom imovinom (ponajprije gotovinom) lokalnih jedinica u kratkom roku može prouzročiti nemogućnost plaćanja.

Kad je u pitanju dug, puno je čimbenika koji mogu utjecati na nemogućnost plaćanja kod lokalnih jedinica. Stanje (visina) izravnog duga vrlo je važan čimbenik, zatim struktura toga duga (ročna, valutna i sl.) te koeficijent pokrića duga. Naime, jednokratno dospijeće duga može prouzročiti velike probleme ukoliko ne dođe do ugovaranja refinanciranja obveze. Također, visoka godišnja razina otplate postojećeg duga (koji na naplatu obično dolazi tromjesečno/kvartalno) može u situaciji smanjenih proračunskih prihoda onemogućit plaćanje dospjelih obveza. Važan je čimbenik i trošak plaćene kamate u ukupnim troškovima. Dodatno,

na nemogućnost plaćanja u velikoj mjeri mogu utjecati i potencijalne obveze, jer u danom trenutku mogu postati direktno opterećenje proračuna.

d) Stanovništvo

Postoji čitav niz socioekonomskih čimbenika koji mogu negativno utjecati na mogućnost pravovremenog ispunjenja obveza lokalnih jedinica. Osnovu svakog gospodarstva čine ljudi stoga čimbenici vezani za demografiju, kao što je broj stanovnika te broj i struktura zaposlenih i nezaposlenih osoba (osobito dugotrajno nezaposlenih osoba), mogu uvelike utjecati na gospodarska kretanja. Dodatno porezno opterećenje može imati negativne posljedice za gospodarstvo te se i to može posljedično reflektirati na broj radnih mjesta. Visoka koncentracija u jednoj ili malom broju gospodarskih grana čini gospodarstvo lokalne jedinice podložnijim negativnim kontrakcijama Bruto domaći proizvod prikazan po stanovniku ili na razini lokalne jedinice važan je pokazatelj te su njegove negativne promjene rezultat pogoršane gospodarske situacije na lokalnom tržištu koje za posljedicu, u pravilu, imaju pad ukupnog dohotka stanovništva, a posljedično onda i pad proračunskih prihoda. Negativna kretnja svih navedenih čimbenika u pravilu direktno utječu na smanjenu prihodovnu stranu lokalnih proračuna. Loša gospodarska kretanja potiče i spora i neučinkovita lokalna uprava te manjak transparentnosti po pitanju financijskog upravljanja, ali i ostalih administrativnih procesa.

5. Financijska i socioekonomska pozicija gradova od 2014. do 2018. godine

Gradovi su ključan segment javnog sektora u pogledu funkcioniranja i razvoja svake države, pa tako i Republike Hrvatske te je stoga vrlo važna njihova financijska i ekonomska pozicija. Analiziran je odnos gradova s drugim razinama vlasti, od središnje države, preko županija pa sve do usporedbe s općinama. Također, značajnu ulogu imaju veliki gradovi (njih 25), a osobito Grad Zagreb, stoga je u analizama prikazan utjecaj svih gradova, velikih gradova (bez Grada Zagreba) te Grad Zagreb.

Kod financijske pozicije analizirani su prihodi i rashodi te njihova struktura u razdoblju od 2014. do 2018. godine. Zatim su analizirani rezultati poslovanja te vrijednost imovine i obveza. Najveći je naglasak stavljen na analizu dospjelih obveza te zaduženost gradova.

Socioekonomska pozicija, s obzirom na dostupnost podataka za gradove u Republici Hrvatskoj, prikazana je kretanjem procijenjenog broja stanovnika, broja zaposlenih i nezaposlenih kao temeljnih gospodarskih pokazatelja. Uspostavljeni indeks razvijenosti, kao kompozitni indeks različitih dostupnih varijabli, izdvojio je najrazvijenije gradove, a ocjena transparentnosti one najtransparentnije gradove u Republici Hrvatskoj.

5.1. Prihodi i rashodi gradova u Republici Hrvatskoj

Gospodarska kretanja, sposobnosti lokalnih jedinica za apsorpcijom sredstava iz nacionalnih i fondova Europske unije te zakonske izmjene u najvećoj mjeri utječu na prihode gradova. Pozitivna gospodarska kretanja, mjerena realnom godišnjom stopom promjene BDP-a[134] koja je u periodu 2014. - 2018. godine prosječno iznosila 2,3 %, direktno su utjecala na porast ukupnih prihoda lokalnih jedinica. Uz to, značajan je i porast prihoda s osnove pomoći temeljem prijenosa EU sredstava koje su, u promatranom razdoblju, dosegnule razinu od preko 300 milijuna kuna u 2018. godini. U promatranom je razdoblju nekoliko puta dolazilo i do zakonskih izmjena koje su dodatno utjecale na ukupne proračunske prihode, ali i njihovu strukturu. Primjerice, smanjenje prihoda od poreza na dohodak u 2017. godini temeljem provedene porezne reforme, kompenzirano je izravnom državnom pomoći u vrijednosti od gotovo pola milijarde kuna.

[134] https://www.hnb.hr/statistika/glavni-makroekonomski-indikatori (pristupljeno: 17. ožujka 2020.).

Ukupni prihod svih lokalnih jedinica u Republici Hrvatskoj na kraju 2018. godine iznosio je 27 milijardi kuna, što je u odnosu na ostvareni prihod u 2014. godini, rast od 4,2 milijarde kuna (tablica br. 26). Najveći rast, od preko 3,1 milijardu kuna, dogodio se u zadnjoj godini promatranog razdoblja. Rezultat je to, prije svega, zakonskih izmjena prema kojima je cjelokupni prihod od poreza na dohodak prepušten lokalnim jedinicama te je uveden model fiskalnog izravnanja kojim se 17 % prikupljenog poreza na dohodak redistribuira slabije razvijenim lokalnim i regionalnim jedinicama.

Prihodi općina u promatranom razdoblju kontinuirano rastu s 3,6 milijardi kuna na početku do skoro 5 milijardi kuna na kraju razdoblja. Uz blagi rast prihoda tijekom prvih godina promatranog razdoblja (2014. godina do 2017. godina), najveće je povećanje vidljivo u posljednjoj promatranoj godini. Naime, u 2018. godini, zbog već spomenutog fiskalnog izravnanja, veliki je broj općina dobio na raspolaganje veća sredstva nego godinu ranije, a posljedično je porastao i udio općina u ukupnim prihodima (1,4 %). Isti je slučaj i s velikom većinom manjih gradova kojima je ukupni prihod u 2018. godini porastao za 1,2 milijarde kuna odnosno 25,6 %. Udio ukupnih prihoda velikih gradova u ukupnim prihodima lokalnih i regionalnih jedinica, unatoč nominalnom rastu, opada u zadnje tri promatrane godine.

Tablica 26. Pregled ukupnih prihoda općina, gradova i županija u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima)

Ukupni prihodi	2014.	2015.	2016.	2017.	2018.	Rast/pad
Općine	3.573	3.699	3.908	4.034	4.929	1.355
Gradovi	15.483	14.802	15.572	15.766	17.899	2.416
Veliki gradovi	5.083	4.972	5.248	5.360	5.782	699
Grad Zagreb	6.651	6.206	6.427	6.572	7.280	630
Županije	3.737	3.716	3.668	4.031	4.138	402
Ukupno	22.793	22.217	23.148	23.830	26.966	4.173
Udio u %						
Općine	15,7 %	16,6 %	16,9 %	16,9 %	18,3 %	2,6 %
Gradovi	67,9 %	66,6 %	67,3 %	66,2 %	66,4 %	-1,6 %
Veliki gradovi	22,3 %	22,4 %	22,7 %	22,5 %	21,4 %	-0,9 %
Grad Zagreb	29,2 %	27,9 %	27,8 %	27,6 %	27,0 %	-2,2 %
Županije	16,4 %	16,7 %	15,8 %	16,9 %	15,3 %	-1,0 %
Ukupno	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	0,0 %

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[135]

[135] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

Važnost gradova odnosno njihov financijski značaj najviše ocrtava činjenica da su, tijekom cijelog promatranog razdoblja, dvije trećine ukupnih prihoda svih lokalnih i regionalnih jedinica ostvarivali gradovi te da je rast prihoda gradova u promatranom razdoblju iznosio 2,4 milijarde kuna. Gradu Zagrebu kontinuirano se smanjuje udio, ali i dalje iznosi visokih 27 % ukupnih prihoda svih lokalnih jedinica odnosno preko 40 % ukupnih prihoda svih gradova u Republici Hrvatskoj.

Najveći pad udjela u ukupnom prihodu lokalnih jedinica, unatoč činjenici da je zakonskim promjena u 2018. godini povećan udio u ukupnom porezu na dohodak sa 16,5 % na 17 %, bilježe županije čiji se udio u odnosu na početak promatranog razdoblja smanjio za 1 %, a u zadnjoj promatranoj godini čak 1,6 %. Unatoč padu udjela, nominalan rast u promatranih 5 godina iznosio je gotovo 402 milijuna kuna.

Utjecaj Grada Zagreba vidljiv je i u pregledu ukupnih prihoda velikih gradova poredanih po visini prihoda u 2018. godini (tablica br. 27). Ukupan prihod svih velikih gradova u navedenoj godini iznosio je 13,1 milijardu kuna, od čega se na Grad Zagreb odnosilo 55,7 %. U promatranom petogodišnjem razdoblju rast ukupnih prihoda velikih gradova iznosio je 1,3 milijarde kuna, a rast su imali svi gradovi osim Karlovca (-5,8 milijuna), Gospića (-5,5 milijuna) i Pazina (-4,5 milijuna). Osim Zagreba čiji je ukupni prihod porastao za 630 milijuna kuna, značajan rast ostvarili su i Dubrovnik (116,8 milijuna kuna) te Split (96,7 milijuna kuna), dok je najveći postotni rast zabilježen kod Virovitice (59,7 %) i Slavonskog Broda (36,6 %).

Ukoliko se usporedba radi nakon pada prihoda u 2015. godini, rast je još izraženiji te za Zagreb iznosi preko milijardu kuna, dok za Split iznosi 150 milijuna kuna. Navedeni pad ukupnih prihoda u 2015. godini, u iznosu od preko pola milijarde kuna, dogodio se zbog izmjena poreza na dohodak u dijelu povećanja osobnog odbitka te promjena poreznih razreda[136] s ciljem poreznog rasterećenja građana. Snažan rast, od preko 1,1 milijardu kuna, vidljiv je na samom kraju promatranog razdoblja temeljem već spomenutih zakonskih izmjena u 2018. godini.

[136] Osobni odbitak porastao je s 2.200 kuna na 2.600 kuna. Porezna stopa od 25 % primijenila se na razliku između 2.200 kuna i 13.200 kuna, a porezna stopa od 40 % na poreznu osnovicu iznad 13.200 kuna mjesečno.

Tablica 27. Pregled ukupnih prihoda velikih gradova u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima, uređenje prema silaznoj vrijednosti varijable u 2018. godini)

Ukupni prihodi	2014.	2015.	2016.	2017.	2018.	Udio u 2018.	Rast / pad
Zagreb	6.651	6.206	6.427	6.572	7.280	55,7 %	630
Split	729	677	744	792	826	6,3 %	97
Rijeka	673	680	680	671	739	5,7 %	66
Dubrovnik	375	375	387	402	492	3,8 %	117
Osijek	382	346	355	388	408	3,1 %	26
Zadar	351	345	374	362	370	2,8 %	19
Pula	280	271	307	349	310	2,4 %	30
Velika Gorica	230	265	246	326	266	2,0 %	37
Varaždin	220	212	229	221	237	1,8 %	17
Karlovac	211	196	237	209	205	1,6 %	-6
Samobor	170	211	205	177	195	1,5 %	25
Šibenik	184	163	164	174	192	1,5 %	8
Sisak	168	167	172	177	186	1,4 %	18
Slavonski Brod	133	137	144	151	181	1,4 %	49
Vukovar	132	111	154	154	171	1,3 %	39
Kaštela	107	105	121	105	136	1,0 %	30
Koprivnica	118	133	118	117	135	1,0 %	17
Virovitica	83	83	70	64	132	1,0 %	50
Bjelovar	108	107	114	113	127	1,0 %	19
Čakovec	102	99	106	114	114	0,9 %	12
Vinkovci	97	86	117	88	110	0,8 %	13
Požega	72	65	65	67	92	0,7 %	20
Gospić	68	58	54	55	62	0,5 %	-5
Pazin	60	49	50	51	55	0,4 %	-4
Krapina	30	32	36	34	38	0,3 %	7
Ukupno	**11.734**	**11.178**	**11.675**	**11.932**	**13.062**	**100,0 %**	**1.328**

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[137]

Kao što je već ranije pojašnjeno, ukupni prihodi svih gradova i Grada Zagreba sastoje se od prihoda poslovanja (97,6 % ukupnih prihoda) te prihoda od prodaje nefinancijske imovine (2,4 %).

[137] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga. 2020.).

U strukturi prihoda poslovanja, prikazanoj u tablici br. 28, materijalno najznačajniju ulogu imaju prihodi od različitih vrsta poreza. Od ukupno 17,5 milijardi kuna u 2018. godini, 63,4 % odnosno 11,1 milijardu kuna, odnosilo se na prihode po toj osnovi.

Drugi najznačajniji prihod činili su prihodi od upravnih i administrativnih pristojbi, zatim pristojbe po posebnim propisima i naknada. Navedeni je prihod porastao s 2,8 milijardi kuna u 2014. godini na 3,2 milijarde kuna u 2018. godini dok je utjecaj na ukupni prihod, snažnim rastom poreznih prihoda, *oslabio* na 18 %. Najznačajniji rast u ovoj kategoriji gradovi su ostvarili na pozicijama komunalnog doprinosa i naknada, a navedena je pozicija i svojim udjelom najznačajnija (84,9 % u 2018. godini). Naime, navedeni prihodi kontinuirano rastu u periodu od 2014. do 2018. godine te je kumulirani prihod komunalnog doprinosa gradova porastao za 108,5 milijuna kuna (19,8 %), a kumulirani prihod komunalne naknade za 236,1 milijun kuna (13,3 %).

Preostala dva značajna prihoda poslovanja odnose se na prihode od pomoći iz inozemstva i od subjekata unutar općeg proračuna (9,8 % udjela u 2018. godini) te prihoda od imovine (7,7 % udjela u 2018. godini). Gradovima su prihodi od pomoći u petogodišnjem razdoblju porasli za 413,6 milijuna kuna. U najvećoj se mjeri taj porast odnosi na porast pomoći izravnanja za decentralizirane funkcije u iznosu od 148,7 milijuna kuna, zatim porast tekućih pomoći temeljem prijenosa EU sredstava u iznosu 101,1 milijun kuna, te kapitalne pomoći temeljem prijenosa EU sredstava u iznosu od 205,5 milijuna kuna.

Veliki, jednokratni porast pomoći vidljiv je u 2017. godini zbog donesene kompenzacijske mjere Ministarstva financija kojom je ministarstvo nadoknađivalo izgubljeni porezni prihod lokalnih jedinica direktnom pomoći iz državnog proračuna nakon provedenog novog kruga porezne reforme[138].

Prihodi od imovine su stabilni tijekom promatranog razdoblja, te se oni u najvećoj mjeri odnose na prihode od zakupa i iznajmljivanja imovine (gotovo polovina prihoda od imovine), pa je njihov utjecaj na ukupne prihode poslovanja postupno oslabio.

[138] Novom poreznom reformom ukinuta je stopa poreza od 12 %, dok su smanjene stope poreza na dohodak s 25 % na 24 % i s 40 % na 36 %, te je povećan osobni odbitak na 3.600 kuna.

Tablica 28. Struktura prihoda poslovanja gradova u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima)

Struktura prihoda poslovanja	2014.	2015.	2016.	2017.	2018.	Rast / pad
Prihodi od poreza	9.474	8.590	9.179	8.766	11.076	1.602
Pomoć iz inozemstva i od subjekata unutar općeg proračuna	1.223	1.440	1.540	1.912	1.637	414
Prihodi od imovine	1.245	1.267	1.221	1.246	1.347	102
Prihodi od upravnih i administrativnih pristojbi, pristojbi po posebnim propisima i naknada	2.809	2.916	2.999	3.070	3.148	340
Prihodi od prodaje proizvoda i robe te pruženih usluga i prihodi od donacija	105	76	90	74	92	-12
Prihodi iz nadležnog proračuna i od HZZO-a na temelju ugovornih obveza	1	0	0	0	0	-1
Kazne, upravne mjere i ostali prihodi	133	146	117	120	162	29
Ukupno	14.989	14.436	15.144	15.189	17.461	2.473
Udio u %						
Prihodi od poreza	63,2 %	59,5 %	60,6 %	57,7 %	63,4 %	0,2 %
Pomoć iz inozemstva i od subjekata unutar općeg proračuna	8,2 %	10,0 %	10,2 %	12,6 %	9,4 %	1,2 %
Prihodi od imovine	8,3 %	8,8 %	8,1 %	8,2 %	7,7 %	-0,6 %
Prihodi od upravnih i administrativnih pristojbi, pristojbi po posebnim propisima i naknada	18,7 %	20,2 %	19,8 %	20,2 %	18,0 %	-0,7 %
Prihodi od prodaje proizvoda i robe te pruženih usluga i prihodi od donacija	0,7 %	0,5 %	0,6 %	0,5 %	0,5 %	-0,2 %
Prihodi iz nadležnog proračuna i od HZZO-a na temelju ugovornih obveza	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %
Kazne, upravne mjere i ostali prihodi	0,9 %	1,0 %	0,8 %	0,8 %	0,9 %	0,0 %
Ukupno	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	0,0 %

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[139]

[139] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

Struktura najznačajnijeg prihoda poslovanja gradova sastoji se od nekoliko vrsta različitih poreza od kojih porez i prirez na dohodak ima najznačajniju ulogu (tablica br. 29). Zbog rasta udjela poreza na imovinu koji kontinuirano raste u promatranom razdoblju s početnih 5,5 % na završnih 9,9 %, dolazi do smanjenja udjela poreza i prireza na dohodak s 91,3 % na 88,6 %. Najvažniji razlog tako naglog rasta poreza na imovinu vezan je za povremene poreze na imovinu, točnije na porez na promet nekretninama. Naime, poslove utvrđivanja i naplate navedenog poreza za gradove obavlja Ministarstvo financija, tj. Porezna uprava. Intenziviranjem aktivnosti vezanih za naplatu potraživanja s osnove poreza na promet nekretnina te bržim postupcima naplate novoizdanih rješenja, dijelom već u 2017. godini, a u punom smislu u 2018. godini, dolazi do naglog porasta prihoda po ovoj osnovi. Povremeni su porezi na imovinu u 2015. godini ostvareni u iznosu od 423,2 milijuna kuna, a u 2018. godini u iznosu od 933,5 milijuna kuna.

Tablica 29. Struktura poreznih prihoda gradova u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima)

Struktura poreznih prihoda	2014.	2015.	2016.	2017.	2018.	Rast / pad
Porez i prirez na dohodak	8.653	7.697	8.228	7.769	9.778	1.125
Porezi na imovinu	525	589	632	772	1.093	569
Porezi na robu i usluge	296	303	316	221	204	-92
Ostali prihodi od poreza	0	1	2	3	0	0
Ukupno porezni prihodi	9.474	8.590	9.179	8.766	11.076	1.602
Udio u %						
Porez i prirez na dohodak	91,3 %	89,6 %	89,6 %	88,6 %	88,3 %	-3,1 %
Porezi na imovinu	5,5 %	6,9 %	6,9 %	8,8 %	9,9 %	4,3 %
Porezi na robu i usluge	3,1 %	3,5 %	3,4 %	2,5 %	1,8 %	-1,3 %
Ostali prihodi od poreza	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %	0,0 %
Ukupno	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	0,0 %

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[140]

Sve važniji dio ukupnih prihoda lokalnih jedinica čini i pomoć iz inozemstva. Uglavnom je to: pomoć od inozemnih vlada, pomoć od međunarodnih organizacija te institucija i tijela Europske unije te pomoć temeljem prijenosa sredstava iz fondova Europske unije. Navedena je pomoć važan izvor dodatnih sredstava potrebnih za razvoj lokalnih i regionalnih jedinica, a pregled *povlačenja* inozemnih sredstava prikazan je tablicom br. 30.

[140] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

Tijekom promatranog razdoblja porastao je, preko devet puta, iznos koji lokalne jedinice primaju kao pomoć iz inozemstva, a preko četiri puta iznos koji primaju županije. Ukupni prihodi svih jedinica porasli su s početnih 129 milijuna kuna na gotovo 866 milijuna kuna na kraju promatranog razdoblja. Županije su u tom periodu imale kontinuiran rast dok gradovi i općine iz značajno osciliraju.

Tablica 30. Pregled pomoći iz inozemstva općinama, gradovima i županijama u razdoblju od 2014. do 2018. godine (u 000 kuna i postotcima)

Inozemna pomoć	2014.	2015.	2016.	2017.	2018.
Općine	14.748	68.291	127.538	48.880	226.340
Gradovi	46.865	110.788	279.619	98.342	352.681
Županije	67.494	160.042	253.941	272.253	286.867
Ukupno	**129.106**	**339.121**	**661.098**	**419.476**	**865.888**
Udio u %					
Općine	11,4 %	20,1 %	19,3 %	11,7 %	26,1 %
Gradovi	36,3 %	32,7 %	42,3 %	23,4 %	40,7 %
Županije	52,3 %	47,2 %	38,4 %	64,9 %	33,1 %
Ukupno	**100,0 %**	**100,0 %**	**100,0 %**	**100,0 %**	**100,0 %**

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[141]

Pomoć od međunarodnih organizacija te institucija i tijela EU kod gradova najviše osciliraju, ali je ukupan iznos na početku i na kraju promatranog razdoblja gotovo jednak i iznosio je gotovo 44 milijuna kuna godišnje. Oscilacije su vidljive u pojedinim godinama pa je primjerice u 2017. godini ostvareno 11 milijuna kuna tekuće pomoći od institucija i tijela EU, a već sljedeće godine preko 30 milijuna kuna. Radi se o pomoći koje gradovi direktno primaju od projektnih partnera iz inozemstva. Značajno je drugačija situacija vezana kod pomoći temeljem prijenosa EU sredstava. Naime, gradovi navedenu pomoć primaju preko institucija u Republici Hrvatskoj, a ta vrsta pomoći porasla je preko 306 milijuna kuna, jer su na nacionalnoj razini povećane aktivnosti vezane za iskorištavanje dostupnih europskih fondova. S porastom proračunskih prihoda, dolazi posljedično i do rasta ukupnih proračunskih rashoda lokalnih jedinica. Ukupni su rashodi, u promatranom periodu, ipak manje porasli nego ukupni prihodi te je njihov rast iznosio 3,6 milijardi kuna odnosno na kraju 2018. godine iznosili su 26,9 milijardi kuna. U tablici br. 31 prikazan je pregled ukupnih rashoda prema razinama lokalnih i regionalnih jedinica, ali dodana je i usporedba s državnim proračunom. Iako je dio rashoda državnog proračuna automatski i prihod proračuna lokalnih jedinica[142], zanimljivo je primijetiti

[141] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).
[142] Radi se primjerice o tekućim i kapitalnim pomoćima te pomoćima izravnanja za decentralizirane funkcije.

da je rashodovna strana državnog proračuna 5 puta veća od rashodovne strane svih nižih jedinica vlasti. Unatoč kontinuiranom rastu rashodovne strane državnog proračuna u periodu od 2015. godine do kraja promatranog razdoblja, rast rashoda lokalnih proračuna raste po većim stopama[143].

Tablica 31. Pregled ukupnih rashoda općina, gradova i županija u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima)

Ukupni rashodi	2014.	2015.	2016.	2017.	2018.	Rast/pad
Općine	3.486	3.642	3.744	4.035	4.798	1.312
Gradovi	16.166	14.518	15.566	15.992	17.883	1.717
Veliki gradovi	4.996	4.908	5.105	5.123	5.675	679
Grad Zagreb	7.633	6.098	6.680	6.950	7.569	-64
Županije	3.613	3.627	3.676	3.950	4.181	569
Ukupno	23.265	21.787	22.986	23.977	26.863	3.598
Proračun RH	127.546	118.608	120.238	124.999	129.587	2.040
Odnos	18,2 %	18,4 %	19,1 %	19,2 %	20,7 %	
Udio u %						
Općine	15,0 %	16,7 %	16,3 %	16,8 %	17,9 %	2,9 %
Gradovi	69,5 %	66,6 %	67,7 %	66,7 %	66,6 %	-2,9 %
Veliki gradovi	21,5 %	22,5 %	22,2 %	21,4 %	21,1 %	-0,3 %
Grad Zagreb	32,8 %	28,0 %	29,1 %	29,0 %	28,2 %	-4,6 %
Županije	15,5 %	16,6 %	16,0 %	16,5 %	15,6 %	0,0 %
Ukupno	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	0,0 %

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[144]

Ukupni rashodi općina i županija u promatranom periodu u potpunosti su pratili rast ukupnih proračunskih prihoda, dok kod gradova situacija nije tako jednostavna i jednoznačna. Naime, rast ukupnih proračunskih rashoda svih gradova iznosio je 1,7 milijardi kuna i u usporedbi s rastom ukupnih proračunskih prihoda u promatranom razdoblju, koji su u istom razdoblju rasli 2,4 milijarde kuna, može se zaključiti da su gradovi kontinuirano imali višak prihoda nad rashodima. Ukupnu perspektivu omjera prihoda/rashoda gradova kvari činjenica da je Grad Zagreb u 2014. godini imao gotovo milijardu kuna veće ukupne rashode od ukupnih prihoda. Razlog je robni kredit[145] koji je Grad Zagreb realizirao sa Zagrebačkim holdingom na rok od 10 godina, a radi se o kupovini dvije nekretnina koje nisu bile u funkciji poslovanja holdinga (bivša Tvornica željezničkih vozila Gredelj i Zagrepčanka), a predstavljaju kulturno dobro grada. U periodu od 2016. godine do 2018. godine, Grad Zagreb i dalje, svake godine, ima veće

[143] U 2016. godini porast rashoda bio je 5,5 %, u 2017. godini 4,3 %, a u 2018. godini čak 12 %.
[144] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 i https://mfin.gov.hr/proracun-86/drzavni-proracun-arhiva/610 (pristupljeno: 11. studenoga 2020.).
[145] „Robni je kredit vrsta kredita koji se odobrava i vraća u robi“. (Srb, Matić, 2003:51)

ukupne rashode od ukupnih prihoda, a razlika se kretala od 253 milijuna u 2016. godini do 378 milijuna kuna u 2017. godini. Pregled rezultata poslovanja svih velikih gradova odnosno njihovih viškova prihoda i primitaka u tekućoj godini, ali i manjkova prihoda i primitaka prikazan je u tablici br. 32.

Tablica 32. Pregled rezultata tekuće godine velikih gradova u razdoblju od 2014. do 2018. godine (u 000 kuna, uređenje prema silaznoj vrijednosti manjka, pa viška u 2018. godini)

Rezultat	2014.	2015.	2016.	2017.	2018.
Zagreb	11.461	29.432	61.340	384.977	50.934
Velika Gorica	13.234	17.731	10.983	1.425	13.098
Vukovar	35.705	13.471	6.587	22.242	6.959
Čakovec	262	6.396	51	4.918	4.742
Vinkovci	5.877	273	4.633	3.290	4.437
Split	1.178	1.346	15.369	102.887	4.072
Požega	1.202	1.349	25	2.794	3.979
Pula	6.676	853	18.053	30.055	3.135
Bjelovar	5.789	588	56	1.258	101
Karlovac	6.445	1.541	8.009	11.361	53
Slavonski Brod	6.188	8.025	5.378	4.407	32.972
Rijeka	25.057	12.404	254	20.545	18.881
Kaštela	4.911	1.128	18.182	8.269	18.795
Zadar	11.558	11	2.197	4.615	17.116
Šibenik	589	14.678	3.688	1.751	9.403
Varaždin	9.192	4.325	20.270	21.346	8.503
Dubrovnik	4.015	16.238	22.687	22.981	8.203
Koprivnica	5.406	3.330	5.626	5.966	8.090
Sisak	13	2.855	6.767	8.644	6.108
Osijek	1.509	9.474	19.229	11.484	4.004
Virovitica	10.107	8.469	1.128	3.743	3.646
Krapina	44	611	2.300	3.056	1.520
Gospić	108	2.848	1.903	1.190	465
Samobor	6.628	3.348	2.888	4.350	157
Pazin	772	505	612	2.438	5
Ukupno manjak	**101.665**	**80.963**	**103.840**	**460.839**	**91.510**
Ukupno višak	**72.261**	**80.264**	**134.375**	**229.156**	**137.870**

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[146] (crvenim brojkama označeni su manjkovi, a crnim brojkama viškovi prihoda).

Gradovi su poredani temeljem rezultata u 2018. godini, te su prvo prikazani gradovi s najvećim manjkom, a tek onda gradovi s najvećim proračunskim viškom. Na kraju 2018. godine 10 velikih gradova ostvarilo je tekući manjak u ukupnom iznosu od 91,5 milijuna kuna (od čega se 56 % odnosilo na Grad Zagreb), dok je preostalih 15 gradova ostvarilo tekući višak u iznosu

[146] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

od 137,9 milijuna kuna. Osim Zagreba, unatoč pozitivnim rezultatima u 2018. godini, visoke manjkove u ranijim godinama iskazuju gradovi Rijeka i Šibenik. Od svih promatranih gradova, jedino je Osijek u kontinuitetu ostvarivao tekući višak. Ukupno su gradovi u periodu od 2014. do 2018. godine ostvarili 828,8 milijuna kuna tekućeg manjka, te 653,9 milijuna kuna tekućeg viška, odnosno rezultat svih gradova je tekući manjak u iznosu 184,9 milijuna kuna.

Negativan rezultat tekuće godine ne mora nužno predstavljati negativnu stvar, jer se može raditi o trošenju viška iz prethodnog razdoblja, kao što dugotrajniji tekući višak može značiti saniranje velikog proračunskog manjak (npr. slučaj kod Osijeka). Zato je važno, uz podatak o tekućem višku, sagledati i ukupan rezultat poslovanja. Naime, zbrajanjem prenesenog rezultata iz prethodnih godina s rezultatom za tekuću godinu, dolazi se do viška prihoda i primitaka raspoloživog u sljedećem razdoblju ili pak do manjka prihoda i primitaka koji se treba pokriti u nadolazećem razdoblju (tablica br. 33). Odmah se može primijetiti da je ukupno prikazani manjak na kraju 2018. godine iznosio nešto više od milijardu kuna, a prvenstveno zbog Grada Zagreba koji ima izrazito veliki preneseni manjak. Ukupno je, uz Zagreb, još 13 gradova prikazalo ovu vrstu manjka od kojih je Rijeka, tijekom cijelog promatranog razdoblja, imala prosječno skoro 250 milijuna kuna manjka. Rijeka je u 2018. godini imala omjer prenesenog manjka prihoda i primitaka za pokriće u sljedećem razdoblju i ukupnih prihoda na visokih 33,7 %, odnosno trećina budućeg proračuna (bez primitaka) potrebna je za saniranje tolikog manjka. U nešto se boljoj situaciji nalaze Šibenik (17,2 %) i Zadar (16,2 %). Navedeni je pokazatelj za Grad Zagreb iznosio 8,6 %. Kratkotrajan manjak s ovim pokazateljem manjim od 5 %, ne mora značajnije utjecati na likvidnost lokalnih jedinica, ali kontinuitet prenesenog manjka s visokim iznosom manjka potrebnog za pokriće u budućem razdoblju, u pravilu, onemogućava plaćanje dospjelih obveza na vrijeme i u punom iznosu.

Od ukupno 11 gradova koji su na kraju 2018. godine iskazali preneseni višak raspoloživ u sljedećem razdoblju, važno je istaknuti gradove Slavonski Brod, Vukovar, Dubrovnik, Karlovac, Krapinu i Bjelovar koji kontinuirano u promatranom razdoblju raspolažu s ostvarenim viškom te Osijek koji je kontinuirano smanjivao preneseni manjak, da bi 2018. završio s prenesenim viškom.

Tablica 33. Pregled prenesenog viška/manjka prihoda i primitaka raspoloživog/za pokriće u sljedećem razdoblju velikih gradova u razdoblju od 2014. do 2018. godine (u 000 kuna, uređenje prema silaznoj vrijednosti prenesenog manjka, pa prenesenog viška u 2018. godini)

Preneseni višak / manjak	2014.	2015.	2016.	2017.	2018.
Zagreb	172.540	131.699	193.039	578.016	628.950
Rijeka	234.369	246.772	247.026	267.571	248.690
Zadar	86.071	83.471	81.275	77.130	59.950
Šibenik	16.866	35.730	40.018	42.429	33.026
Koprivnica	16.883	13.553	19.734	25.710	17.667
Vinkovci	6.569	6.843	2.209	5.499	9.936
Čakovec	2.038	8.434	8.491	3.573	8.500
Pazin	5.302	4.796	4.422	6.860	6.855
Samobor	4.136	788	2.090	6.514	6.357
Velika Gorica	8.049	4.705	6.278	7.703	5.395
Gospić	877	1.971	3.874	4.851	3.966
Sisak	10.008	7.068	212	8.856	2.747
Virovitica	3.918	4.525	2.219	5.962	2.315
Požega	1.385	145	170	2.625	1.371
Pula	2.670	1.524	16.529	46.584	43.448
Slavonski Brod	6.197	14.222	6.034	10.441	43.408
Vukovar	35.853	21.969	28.175	49.146	42.125
Dubrovnik	9.572	25.810	3.123	26.104	34.307
Varaždin	27.038	22.714	2.444	18.902	27.405
Split	81.943	83.548	68.474	33.750	25.126
Kaštela	7.548	6.627	11.557	3.288	22.071
Karlovac	11.491	10.973	19.000	7.639	7.285
Osijek	40.500	31.026	11.796	312	3.693
Krapina	1.933	2.558	4.858	1.802	3.322
Bjelovar	1.004	1.592	1.647	131	30
Ukupno manjak	**711.730**	**695.151**	**687.492**	**1.033.282**	**1.035.726**
Ukupno višak	**83.030**	**77.912**	**97.201**	**208.114**	**252.220**

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[147]; (crvenim brojkama označeni su manjkovi, a crnim brojkama viškovi prihoda).

U strukturi rashoda, a vezano za zaduživanje, značajnu ulogu igraju financijski rashodi. Oni se sastoje od kamata za izdane vrijednosne papire, kamata za primljene kredite i zajmove te ostalih financijskih rashoda. Budući da u 2018. godini niti jedan grad nije imao trošak kamata za izdane vrijednosne papire, te da kategorija ostalih financijskih rashoda (koja u sebi sadrži i poziciju ostalih nespomenutih financijskih rashoda na koju se evidentiraju najrazličitiji financijski

[147] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

rashodi koji nisu drugdje raspoređeni) ima snažne oscilacije koje nisu nužno vezane za zaduživanje, napravljena je usporedba općina, gradova i županija temeljem troškova kamata za primljene kredite i zajmove (tablica br. 34).

Tablica 34. Pregled rashoda za kamate za primljene kredite i zajmove općina, gradova i županija u razdoblju od 2014. do 2018. godine (u 000 kuna i postotcima)

Kamate za primljene kredite i zajmove	2014.	2015.	2016.	2017.	2018.	Rast/pad
Općine	14.783	15.525	13.870	11.764	11.696	-3.087
Gradovi	151.071	140.913	129.551	124.518	104.624	-46.447
Veliki gradovi	37.949	35.867	34.357	32.082	27.653	-10.296
Grad Zagreb	90.013	84.926	76.973	72.581	58.067	-31.947
Županije	17.293	7.504	6.551	7.702	7.507	-9.786
Ukupno	**183.146**	**163.942**	**149.972**	**143.984**	**123.827**	**-59.319**
Udio						
Općine	8,1 %	9,5 %	9,2 %	8,2 %	9,4 %	1,4 %
Gradovi	82,5 %	86,0 %	86,4 %	86,5 %	84,5 %	2,0 %
Veliki gradovi	20,7 %	21,9 %	22,9 %	22,3 %	22,3 %	1,6 %
Grad Zagreb	49,1 %	51,8 %	51,3 %	50,4 %	46,9 %	-2,3 %
Županije	9,4 %	4,6 %	4,4 %	5,3 %	6,1 %	-3,4 %
Ukupno	**100,0 %**	**100,0 %**	**100,0 %**	**100,0 %**	**100,0 %**	**0,0 %**

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[148]

Najveći dio troškova plaćaju gradovi (84,5 %), a na Grad Zagreb otpada gotovo polovina plaćenih kamata svih lokalnih i regionalnih jedinica (u nekim godinama čak i više od polovine). Tijekom promatranog razdoblja, kontinuiran je trend smanjenja troškova kamata na dug svih prikazanih razina vlasti. Ukupno se trošak smanjio za gotovo 60 milijuna kuna na godišnjoj razini odnosno za gotovo trećinu. Glavni su razlozi pad referentnih kamatnih stopa uz koje su vezani krediti s promjenjivim kamatnim stopama (ušteda na kamatama za postojeća zaduženja), te ugovaranje novih kredita po boljim uvjetima zbog velike likvidnosti u bankarskom sektoru i zbog namjenskih kreditnih linija razvojnih banaka (prije svega HBOR-a).

5.2. Imovina i obveze gradova u Republici Hrvatskoj

Gradovi raspolažu velikom i vrijednom imovinom koja je na kraju 2018. godine iznosila 97,4 milijarde kuna. Od tog se iznosa 17,8 milijardi kuna odnosilo na imovinu Grada Zagreba, a 46,4 milijarde kuna na ostale velike gradove u Republici Hrvatskoj. Nefinancijska imovina gradova iznosila je 78,9 milijardi kuna, dok je financijska imovina iznosila 18,5 milijardi kuna (tablica

[148] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

br. 35). Važno je i napomenuti da gradovi u svojim bilancama ne vode svu nefinancijsku imovinu po tržišnoj vrijednosti. Dio imovine gradova se još uvijek vodi bez vrijednosti[149] ili ju je teško procijeniti (npr. radi se o radi se o starim gradskim jezgrama, nerazvrstanim cestama, parkovima i sl.) pa je za pretpostaviti da je stvarna vrijednost imovine značajno veća. Mnogi gradovi, primjerice, poslovne prostore i stanove u svojim knjigama vode prema vrijednosti arbitražnih odluka kojima se imovina dijelila između pravnih sljednika bivših općina (početkom devedesetih godina prošlog stoljeća) te se nikada nije radila revalorizacija takve imovine. Knjigovodstvena je vrijednost takve imovine značajno niža od stvarne, tržišne vrijednosti.

Tablica 35. Vrijednost financijske imovine općina, gradova i županija u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima)

Financijska imovina velikih gradova	2014.	2015.	2016.	2017.	2018.
Novac u banci i blagajni	483	440	393	531	684
Depoziti, jamčevni polozi i potraživanja od zaposlenih te za više plaćene poreze i ostalo	172	124	142	147	135
Potraživanja za dane zajmove	140	161	147	132	99
Vrijednosni papiri	19	19	18	18	15
Dionice i udjeli u glavnici	9.780	10.118	10.131	10.206	10.205
Potraživanja za prihode poslovanja	2.703	2.674	2.609	2.975	1.824
Potraživanja od prodaje nefinancijske imovine	835	728	728	764	372
Rashodi budućih razdoblja i nedospjela naplata prihoda	256	124	123	109	87
Ukupno veliki gradovi	**14.388**	**14.388**	**14.292**	**14.881**	**13.422**
Ostali gradovi	4.950	4.953	5.050	5.019	5.055
Općine	4.697	4.871	4.966	5.040	5.230
Županije	1.966	1.828	1.847	1.881	1.816
Ukupno JLS	26.000	26.040	26.154	26.821	25.522
Udio u %					
Ukupno veliki gradovi	**55,3 %**	**55,3 %**	**54,6 %**	**55,5 %**	**52,6 %**
Ostali gradovi	19,0 %	19,0 %	19,3 %	18,7 %	19,8 %
Općine	18,1 %	18,7 %	19,0 %	18,8 %	20,5 %
Županije	7,6 %	7,0 %	7,1 %	7,0 %	7,1 %
Ukupno JLS	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[150]

Financijska imovina velikih gradova na kraju promatranog razdoblja iznosila je 13,4 milijarde kuna odnosno više od polovine financijske imovine svih lokalnih i regionalnih jedinica koja je

[149] Državna revizija naložila je gradovima 2013. godine da se nekretnine koje su bez vrijednosti u poslovnim knjigama, evidentiraju s vrijednošću od 1 kune.
[150] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

iznosila 25,5 milijardi kuna. Ostali gradovi raspolagali su s financijskom imovinom u vrijednosti 5 milijardi kuna, dok su općine i županije raspolagale s ukupno nešto više od 7 milijardi kuna imovine.

Najveći dio vrijednosti financijske imovine velikih gradova odnosi se na dionice i udjele u glavnici (76 % u 2018. godini) koje oni imaju u svojim trgovačkim društvima, odnosno primarno u komunalnim poduzećima koja se bave odvozom komunalnog otpada, proizvodnjom i opskrbom vode, gradskim prijevozom putnika te upravljanjem grobljima. U ukupnom iznosu od 10,2 milijarde kuna vode se u pravilu udjeli u vrijednosti temeljnog kapitala, a ne stvarna (tržišna) vrijednost tih udjela, ali njihov je značaj za pojedini grad vrlo često značajno veći od same nominalne vrijednosti navedenih udjela. Važan su dio financijske imovine i potraživanja za prihode poslovanje. Iako je u 2018. godini došlo da značajnog prikazanog smanjenja potraživanja od preko 1,1 milijardu kuna, ono je rezultat ispravka vrijednosti (zbog primjene članka 37.a Pravilnika o proračunskom računovodstvu i računskom planu), naplate potraživanja, ali i otpisa potraživanja. Primjerice Grad Zagreb je temeljem navedenog smanjio svoja potraživanja za 699 milijuna kuna, od čega se na ispravak vrijednosti odnosilo 492 milijuna kuna. Naime, iako je i ranije postojala obveza za iskazivanjem ispravaka vrijednosti potencijalno nenaplativih potraživanja, do stupanja na snagu izmjena u navedenom Pravilniku, samo su gradovi Osijek i Sisak (od velikih gradova) evidentirali ispravke vrijednosti potraživanja u 2017. godini. Godinu kasnije taj se broj povećao na 18 velikih gradova, a iznos ispravaka vrijednosti je porastao sa 65,7 milijuna na 1 073,3 milijuna odnosno više od milijardu kuna. Udio od 13,6 % predstavlja i dalje velik izazov za sve gradove osobito za Zagreb na kojeg se odnosi iznos od 588 milijuna kuna. U zadnje tri promatrane godine, likvidnost velikih gradova postupno raste što je vidljivo iz novčane pozicije te pozicije depozita. Financijska imovina općina značajno je porasla u 2018. godini (189,4 milijuna kuna), dok županije raspolažu najmanjom vrijednosti financijske imovine i nemaju značajne oscilacije.

Imovina lokalnih jedinica financirana je vlastitim sredstvima ili stvaranjem obveza. Obveze, iako čine manji dio pasivne strane bilance lokalnih i regionalnih jedinica (svega oko 6 %), vrlo su bitne za njihovo financijsko poslovanje. Naime, ukupne obveze svih lokalnih i regionalnih jedinica na kraju 2018. godine iznosile su 7,7 milijardi kuna (tablica br. 36), a sastoje se od obveza za rashode poslovanja, obveza za nabavu nefinancijske imovine te obveza za vrijednosne papire, kredite i zajmove.

U promatranom razdoblju prisutan je rast od 467,7 milijuna kuna, a uspoređuju li se zadnje tri godine, vidljiv je rast od čak 1,1 milijardu kuna. Najveći teret obveza nose gradovi te se, od ukupnih obveza, 5,9 milijardi kuna odnosno gotovo 77 % odnosi na obveze gradova. Ključan generator rasta obveza lokalnih jedinica, u zadnje tri godine, čine gradovi čije su obveze u tom razdoblju narasle za 725 milijuna kuna od čega se gotovo 577 milijuna odnosi na Grad Zagreb. U strukturi obveza Grada Zagreba na kraju promatranog razdoblja, preko 71 % odnosno gotovo 1,9 milijardi kuna odnosilo se na obveze za kredite i zajmove, dok je taj postotak bitno manji ako se skupno gledaju svi ostali gradovi i iznosi 47,2 % (obveze za rashode poslovanja iznosile su 40,9 %, a obveze za nefinancijsku imovinu 10,9 %).

Tablica 36. Vrijednost ukupnih obveza općina, gradova i županija u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima)

Ukupne obveze	2014.	2015.	2016.	2017.	2018.	Rast/pad
Općine	970	962	891	954	1.078	108
Gradovi	5.496	5.091	5.152	5.503	5.877	381
Veliki gradovi	2.141	2.019	1.975	1.917	1.929	-212
Grad Zagreb	2.095	1.899	2.030	2.341	2.607	512
Županije	744	598	578	594	722	-21
Ukupno	7.209	6.651	6.621	7.052	7.677	468
Udio u %						
Općine	13,5 %	14,5 %	13,5 %	13,5 %	14,0 %	0,6 %
Gradovi	76,2 %	76,5 %	77,8 %	78,0 %	76,6 %	0,3 %
Veliki gradovi	29,7 %	30,4 %	29,8 %	27,2 %	25,1 %	-4,6 %
Grad Zagreb	29,1 %	28,5 %	30,7 %	33,2 %	34,0 %	4,9 %
Županije	10,3 %	9,0 %	8,7 %	8,4 %	9,4 %	-0,9 %
Ukupno	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	0,0 %

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[151]

Također, važno je napomenuti da su veliki gradovi bez Grada Zagreba smanjili svoje ukupne obveze u promatranom razdoblju za 211,6 milijuna kuna. Županije su u prvom dijelu promatranog perioda smanjivale ukupne obveze da bi od 2016. godine obveze ponovno počele rasti. Kulminacija je uslijedila u 2018. godini kada obveze, u odnosu na prethodnu godinu, rastu 127,7 milijuna kuna (obveze za rashode poslovanja porasle su 47,2 milijuna kuna, a obveze za nefinancijsku imovinu 74,5 milijuna kuna). Kad su u pitanju općine, u prvih tri godine dolazi do smanjivanja ukupnih obveza, da bi onda uslijedio rast u iznosu od 186,3 milijuna kuna.

Ukupne obveze lokalnih i regionalnih jedinica moguće je, osim po vrstama, podijeliti i prema dospjelosti na: dospjele i nedospjele obveze.

[151]https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

U pravilu, velika većina obveza nije u dospijeću, a tome u prilog govori i činjenica da je krajem 2018. godine 85,5 % odnosno preko 6,5 milijardi svih obveza lokalnih i regionalnih jedinica bilo nedospjelo, a svega 1,1 milijarda kuna odnosno 14,5 % činile su dospjele obveze (tablica br. 37). Pozitivan je trend smanjenja ukupnih dospjelih obveza svih navedenih jedinica koje su u promatranom periodu smanjene za 226 milijuna kuna.

Kao što su gradovi nositelji najveće vrijednost obveza, tako su i dospjele obveze vidljivo najveće u njihovim bilancama. Unatoč smanjenju od 90 milijuna kuna u promatranom razdoblju i dalje se 61,5 % svih dospjelih obveza krajem 2018. godine odnosi na gradove, zatim 26,7 % na velike gradove, a 13,8 % na Grad Zagreb. Važno je istaknuti i rast dospjelih obveza kod Grada Zagreba, koje su 2015. i 2016. godine iznosile približno 15 milijuna kuna, da bi na kraju 2018. godine dosegnule razinu od preko 153 milijuna kuna. U istom su razdoblju dospjele obveze ostalih velikih gradova smanjene za 45,4 milijuna kuna.

Tablica 37. Vrijednost dospjelih obveza općina, gradova i županija u razdoblju od 2014. do 2018. godine (u 000 kuna i postotcima)

Dospjele obveze	2014.	2015.	2016.	2017.	2018.	Rast/pad
Općine	400.051	374.896	349.758	343.460	323.976	-76.075
Gradovi	774.488	695.505	618.734	737.490	684.201	-90.287
Veliki gradovi	342.561	398.714	359.409	387.400	297.191	-45.370
Grad Zagreb	47.674	15.555	14.669	80.124	153.081	105.407
Županije	163.916	114.013	154.364	81.583	103.901	-60.015
Ukupno	**1.338.455**	**1.184.415**	**1.122.856**	**1.162.534**	**1.112.077**	**-226.378**
Udio u %						
Općine	29,9 %	31,7 %	31,1 %	29,5 %	29,1 %	-0,8 %
Gradovi	57,9 %	58,7 %	55,1 %	63,4 %	61,5 %	3,7 %
Veliki gradovi	25,6 %	33,7 %	32,0 %	33,3 %	26,7 %	1,1 %
Grad Zagreb	3,6 %	1,3 %	1,3 %	6,9 %	13,8 %	10,2 %
Županije	12,2 %	9,6 %	13,7 %	7,0 %	9,3 %	-2,9 %
Ukupno	**100,0 %**	**100,0 %**	**100,0 %**	**100,0 %**	**100,0 %**	**0,0 %**

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[152]

Visok udio u ukupnim dospjelim obvezama imaju općine (preko 29 % na kraju 2018. godine), te unatoč kontinuiranom smanjenju ukupnog iznosa dospjelih obveza, na kraju 2018. godine i dalje je vrijednost iznosa dospjelih obveza bila visokih 324 milijuna kuna. Županije su imale najmanji udio od 9,3 % odnosno svega 104 milijuna kuna.

[152]https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

Ukupne dospjele obveze u ukupnim obvezama gradova kretale su se u rasponu od 14,5 % u 2014. godini do 11,7 % u 2018 godini. Struktura dospjelih obveza sastoji se od međusobnih obveza proračunskih korisnika, obveza za rashode poslovanja te od obveza za financijsku i nefinancijsku imovinu. Kad su u pitanju gradovi, najveći udio dospjelih obveza vezan je za obveze za rashode poslovanja (tablica br. 38). Otprilike 2/3 svih dospjelih obveza gradova vezano je za obveze za rashode poslovanja, a to su u najvećoj mjeri obveze za materijalne rashode. Osim rashoda poslovanja, značajne dospjele obveze vezane su i za obveze za nabavu nefinancijske imovine, a važno je istaknuti da se ovaj tip dospjelih obveza udvostručio od 2015. do 2018. godine. Obveze za financijsku imovinu značajno su smanjene u promatranom razdoblju te su na kraju promatranog perioda bila ispod 3 % ukupnih dospjelih obveza.

Tablica 38. Struktura dospjelih obveza gradova u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima)

Struktura dospjelih obveza	2014.	2015.	2016.	2017.	2018.	Rast / pad
Međusobne obveze proračunskih korisnika	102	103	95	114	108	7
Obveze za rashode poslovanja	469	459	416	485	428	-41
Obveze za nefinancijsku imovinu	121	66	62	120	129	9
Obveze za financijsku imovinu	83	109	85	18	19	-64
Ukupne dospjele obveze	774	696	619	737	684	-90
Ukupne obveze	5.355	4.972	5.053	5.431	5.858	503
Udio u dospjelim obvezama u %						
Međusobne obveze proračunskih korisnika	13,1 %	14,8 %	15,3 %	15,5 %	15,8 %	2,7 %
Obveze za rashode poslovanja	60,6 %	66,0 %	67,3 %	65,7 %	62,6 %	1,9 %
Obveze za nefinancijsku imovinu	15,6 %	9,5 %	10,0 %	16,3 %	18,9 %	3,3 %
Obveze za financijsku imovinu	10,7 %	15,7 %	13,7 %	2,5 %	2,7 %	-8,0 %
Ukupne dospjele obveze	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	0,0 %
Ukupne dospjele obveze u ukupnim obvezama	14,5 %	14,0 %	12,2 %	13,6 %	11,7 %	-2,8 %

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[153]

Međusobne obveze proračunskih korisnika ne osciliraju značajno, ali je primjetan blagi rast udjela u ukupnim dospjelim obvezama tijekom promatranih godina. Navedene su obveze vezane primjerice za obvezu za naplaćene prihode vodne naknade prema Hrvatskim vodama ili naknade za otkup društvenih stanova temeljem obročne otplate (gdje se dio prihoda uplaćuje u

[153] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/ financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

državni proračun) te bi gradovi trebali povećati brzinu i učinkovitost transfera prikupljenih sredstava građana prema drugim proračunskim korisnicima kako bi se smanjio dug.
Dospjele obveze velikih gradova, uključujući i Grad Zagreb, prikazane su u tablici br. 39 te je vidljivo da je baš Zagreb u 2018. godini imao najveći iznos dospjelih obveza odnosno 34 % svih dospjelih obveza bilo je vezano za Grad Zagreb.

Tablica 39. Pregled dospjelih obveza velikih gradova u razdoblju od 2014. do 2018. godine (u 000 kuna i postotcima, uređenje prema silaznoj vrijednosti varijable u 2018. godini)

Dospjele obveze	2014.	2015.	2016.	2017.	2018.	Prosjek
Zagreb	47.674	15.555	14.669	80.124	153.081	62.221
Rijeka	144.588	172.615	174.743	192.856	128.064	162.573
Zadar	50.526	55.318	50.268	51.186	44.509	50.361
Varaždin	38.777	39.853	22.173	20.725	25.214	29.348
Šibenik	19.610	30.559	35.923	44.583	24.182	30.971
Split	26.489	27.957	17.702	20.259	23.585	23.198
Vinkovci	0	5.755	5.215	7.704	12.376	6.210
Čakovec	5.095	11.259	11.568	6.995	11.380	9.259
Gospić	8	776	2.089	4.848	5.368	2.618
Pula	4.597	3.598	2.396	5.366	4.802	4.152
Koprivnica	5.509	6.599	13.070	14.780	4.523	8.896
Pazin	6.087	4.071	4.279	5.387	4.134	4.791
Sisak	2.370	2.287	3.699	5.863	2.574	3.359
Samobor	2.830	3.985	3.943	3.494	1.686	3.188
Kaštela	8.346	5.077	906	1.269	1.132	3.346
Osijek	3.215	2.914	1.186	156	1.021	1.698
Virovitica	292	4	56	805	760	384
Slavonski Brod	10.982	11.972	7.334	181	529	6.200
Velika Gorica	1.508	4.038	273	76	490	1.277
Požega	1.170	1.598	479	19	306	714
Karlovac	594	243	261	250	286	327
Bjelovar	5.263	1.301	44	227	218	1.411
Vukovar	4.704	6.935	1.805	373	49	2.773
Dubrovnik	0	0	0	0	0	0
Krapina	0	0	0	0	0	0
Ukupno	**390.235**	**414.269**	**374.079**	**467.524**	**450.272**	**419.276**

Izvor: Izračun autora na temelju podataka Ministarstva financija Republike Hrvatske[154]

Ono što je važno napomenuti je da, iako je na kraju promatranog razdoblja Zagreb imao najveći iznos dospjelih obveza, Rijeka kontinuirano ima visoku razinu dospjelih obveza te je prosjek

[154] Dostupno na: https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/ financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

promatranog razdoblja iznosio 162,6 milijuna kuna, što je čak 100 milijuna kuna više od prosjeka Grada Zagreba. Osim njih, postoji čitav niz gradova koji imaju značajne dospjele obveze na kraju promatranih godina te zbog toga i izrazito visoke prosjeke kao što je Zadar s preko 50,3 milijuna, Šibenik s gotovo 31 milijun, Varaždin s 29,4 milijuna i Split s 23,2 milijuna kuna. Ukupan iznos dospjelih obveza u odnosu na ukupno ostvarene prihode velikih gradova na kraju 2018. godine iznosio je 3,5 %, što je na razini prosjeka cijelog petogodišnjeg razdoblja.

5.3. Zaduženost gradova u Republici Hrvatskoj

U ukupnim obvezama lokalnih jedinica važno mjesto pripada dugu temeljenom na izravnom zaduživanju[155], odnosno obvezama za financijske rashode, vrijednosne papire te obvezama za kredite i zajmove. Temeljem provedene usporedne analize zaduženosti lokalnih jedinica u Republici Hrvatskoj i ostalim članicama Europske unije, zaključeno je da su *krajem 2014. godine lokalne jedinice u Republici Hrvatskoj imale dobru financijsku poziciju i nisu bile prezadužene* (Primorac, Petrović 2016: 19). Slična je situacija bila tijekom cijelog promatranog razdoblja. Naime, gotovo 55 % svih obveza lokalnih jedinica u 2018. godini odnosilo se na ovu vrstu duga te je dosegnut iznos od gotovo 4,2 milijarde kuna (tablica br. 40). Dodatno, na obveze za kredite i zajmove odnosilo se 98 % ove vrste duga[156].

Budući je dug lokalnih jedinica dio duga opće države[157] koji je na kraju iste godine iznosio 286 milijardi kuna, udio duga lokalnih jedinica u dugu opće države bio je svega 1,5 %. Gradovi, kao nositelji ove vrste duga, opterećeni su s gotovo 3,5 milijarde kuna u 2018. godini, što je najviši iznos u cijelom promatranom razdoblju, a udio u ukupnom dugu lokalnih jedinica iznosio je na kraju razdoblja gotovo 83 %. Nešto više od polovine toga iznosa odnosilo se na Grad Zagreb, a na preostale velike gradove čak 885 milijuna kuna manje nego na Grad Zagreb. Općine i županije značajno su manje izložene ovoj vrsti duga te su njihove fluktuacije i značajno manje. Dok je kod ostalih velikih gradova prisutan trend razduživanja i smanjenja duga od izravnog zaduživanja, Grad Zagreb povećao je dug u promatranom razdoblju za 367 milijuna kuna te je stoga došlo i do rasta kad se sumarno gledaju iznosi zaduženosti svih velikih gradova.

[155] *Neizravno zaduživanje podrazumijeva davanje jamstva za zaduženje trgovačkom društvu u vlasništvu grada ili ustanovi kojoj je grad osnivač.*
[156] Bajo i Stavljenić (2017) navode *da su najveći vlasnici duga lokalnih jedinica domaće poslovne banke*.
[157] *Dug opće države sastoji se od unutarnjeg i vanjskog duga središnje države, fondova socijalne sigurnosti i lokalne države (krediti i dužnički vrijednosni papiri)* (HNB).

Tablica 40. Visina duga temeljem izravnog zaduživanja općina, gradova i županija te duga opće države u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima)

Dug temeljem izravnog zaduživanja	2014.	2015.	2016.	2017.	2018.	Rast / pad
Općine	431	425	379	376	402	-29
Gradovi	3.365	3.196	3.323	3.316	3.473	108
Veliki gradovi	1.202	1.123	1.085	998	972	-230
Grad Zagreb	1.490	1.444	1.634	1.628	1.857	367
Županije	343	381	354	320	323	-19
Ukupno	**4.139**	**4.002**	**4.056**	**4.012**	**4.198**	**60**
Dug opće države	281.084	286.432	283.762	284.948	286.213	5.129
Udio u %	1,5 %	1,4 %	1,4 %	1,4 %	1,5 %	
Udio u %						
Općine	10,4 %	10,6 %	9,3 %	9,4 %	9,6 %	-0,8 %
Gradovi	81,3 %	79,9 %	81,9 %	82,7 %	82,7 %	1,4 %
Veliki gradovi	29,0 %	28,1 %	26,8 %	24,9 %	23,1 %	-5,9 %
Grad Zagreb	36,0 %	36,1 %	40,3 %	40,6 %	44,2 %	8,2 %
Županije	8,3 %	9,5 %	8,7 %	8,0 %	7,7 %	-0,6 %
Ukupno	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	0,0 %

Izvor: Izračun autora na temelju podatka Ministarstva financija Republike Hrvatske i Hrvatske narodne banke (HNB)[158]

Grad Zagreb nositelj je i 54,4 % obveza za kredite i zajmove (tablica br. 41) svih gradova u Republici Hrvatskoj. Vrijednost obveza za kredite i zajmove Grada Zagreba uvijek je otprilike dvostruko veća od obveza svih ostalih velikih gradova, iako postoje i veliki gradovi koji imaju značajnu kreditnu zaduženost. Primjerice Rijeka, unatoč kontinuiranom smanjivanja obveza za kredite i zajmove, i dalje je visoko zadužena u odnosu na sve preostale velike gradove, s preko 200 milijuna kuna ove vrste obveza. Osijek je 2018. godine *preuzeo* treće mjesto po visini ove vrste duga od Splita. Velika Gorica i Sisak su, u promatranom razdoblju, višestruko povećali svoj dug te je dug Velike Gorice narastao za 58 milijuna kuna, a Siska za 51,2 milijuna kuna. Postoje gradovi i koji su snažno radili na razduživanju, te je za to najbolji primjer Zadar koji je dug za kredite i zajmove smanjio s 99 milijuna kuna na svega 6 milijuna kuna na kraju promatranog razdoblja. Gradovi Vinkovci, Krapina i Kaštela vrlo konzervativno pristupaju zaduživanju te su tijekom cijelog promatranog razdoblja bili minimalno zaduženi.

[158] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.) i https://www.hnb.hr/statistika/statisticki-podatci/opca-drzava/dug-opce-drzave (pristupljeno: 13. studenoga 2020.). *U tablici se prikazuje dug sektora opće države u skladu s Europskim sustavom nacionalnih i regionalnih računa 2010 (ESA 2010), tzv. Mastrihtški ili EDP dug koji predstavlja bruto nominalni konsolidirani dug bez uključene obračunate neplaćene kamate* (HNB).

Tablica 41. Obveze za kredite i zajmove velikih gradova u razdoblju od 2014. do 2018. godine (u 000 kuna i postotcima, uređenje prema silaznoj vrijednosti varijable u 2018. godini)

Obveze za kredite i zajmove	2014.	2015.	2016.	2017.	2018.
Zagreb	1.490.036	1.443.713	1.632.685	1.625.929	1.855.915
Rijeka	251.565	243.120	241.699	210.878	209.604
Osijek	90.330	98.560	90.861	86.179	93.094
Dubrovnik	96.258	105.904	94.118	84.105	92.603
Velika Gorica	18.652	40.289	36.000	58.457	76.705
Sisak	19.280	20.747	47.225	70.820	70.495
Pula	68.997	56.560	52.198	66.625	59.641
Split	52.782	70.725	88.863	86.509	57.882
Požega	9.285	6.122	24.765	37.468	35.470
Virovitica	17.092	13.982	9.274	11.468	30.258
Koprivnica	51.371	47.286	39.696	21.429	30.214
Karlovac	30.548	39.307	36.578	31.690	28.644
Šibenik	37.542	32.467	30.563	34.107	28.641
Slavonski Brod	33.088	23.662	18.449	22.031	28.145
Čakovec	25.557	21.866	37.182	32.594	23.766
Samobor	8.739	4.938	25.589	24.414	21.526
Varaždin	24.442	21.045	17.468	13.920	21.274
Pazin	23.621	21.917	21.232	19.068	17.615
Bjelovar	13.377	16.296	12.780	11.132	12.651
Zadar	98.873	82.524	79.382	38.499	6.000
Gospić	3.281	2.276	5.464	4.565	3.666
Vukovar	1.695	1.597	1.303	1.153	985
Vinkovci	548	0	0	0	545
Krapina	2.600	1.056	549	478	400
Kaštela	0	815	492	153	7
Ukupno veliki gradovi	2.469.561	2.416.773	2.644.415	2.593.671	2.805.745
Ukupno ostali gradovi	614.507	578.688	556.216	641.773	604.959
Ukupno gradovi	**3.084.068**	**2.995.461**	**3.200.631**	**3.235.444**	**3.410.704**
Udio					
Ukupno veliki gradovi	80,1 %	80,7 %	82,6 %	80,2 %	82,3 %
Grad Zagreb	48,3 %	48,2 %	51,0 %	50,3 %	54,4 %
Ukupno ostali gradovi	19,9 %	19,3 %	17,4 %	19,8 %	17,7 %
Ukupno gradovi	**100,0 %**	**100,0 %**	**100,0 %**	**100,0 %**	**100,0 %**

Izvor: Izračun autora na temelju podatka Ministarstva financija Republike Hrvatske [159]

[159]https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

Primitci od financijske imovine i zaduživanja lokalnih jedinica, u promatranom periodu, sastojali su se najviše od primitaka od zaduživanja, te se od ukupno 1,2 milijarde kuna primitaka lokalnih jedinica u 2018. godini (tablica br. 42), preko 91 % odnosilo na ovu vrstu primitaka. Kod gradova, taj je postotak još i veći odnosno kretao se od 97 % primitaka na početku razdoblja do nešto iznad 95 % na kraju razdoblja. Osim toga, važna su stavka primljeni povrati glavnice danih zajmova i depozita te primitci od prodaje dionica i udjela u glavnici. U promatranom razdoblju nije bilo primitaka od izdanih vrijednosnih papira odnosno lokalne jedinice su u potpunosti prešle na zaduživanje putem kredita i zajmova.

Tablica 42. Primitci od financijske imovine i zaduživanja općina, gradova i županija u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima)

Primitci od financijske imovine i zaduživanja	2014.	2015.	2016.	2017.	2018.	Rast / pad
Općine	179	169	151	137	152	-27
Gradovi	1.490	448	889	853	966	-524
Veliki gradovi	198	135	218	244	217	18
Grad Zagreb	1.193	194	446	369	566	-627
Županije	71	77	130	69	88	16
Ukupno	1.740	694	1.170	1.059	1.206	-534
Udio u %						
Općine	10,3 %	24,3 %	12,9 %	12,9 %	12,6 %	2,3 %
Gradovi	85,6 %	64,5 %	76,0 %	80,6 %	80,1 %	-5,5 %
Veliki gradovi	11,4 %	19,4 %	18,6 %	23,0 %	18,0 %	6,6 %
Grad Zagreb	68,6 %	28,0 %	38,1 %	34,8 %	46,9 %	-21,6 %
Županije	4,1 %	11,1 %	11,1 %	6,5 %	7,3 %	3,2 %
Ukupno	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	0,0 %

Izvor: Izračun autora na temelju podatka Ministarstva financija Republike Hrvatske [160]

U strukturi primitaka od financijske imovine i zaduživanja, gradovi prednjače i kreću se u rasponu od 76 % do 86 % uz izuzetak 2015. godine kad je Grad Zagreb primitke od zaduživanja ostvario u vrijednosti manjoj od 200 milijuna kuna. Primitci od financijske imovine i zaduživanja Grada Zagreba bili su, u 2018. godini, za 400 milijuna kuna veći od sume svih ostalih velikih gradova. Na sve ostale gradove u istoj se godini odnosilo svega 20 % ukupnih primitaka, a dodatnih se 20 % odnosilo na općine i županije.

Izdatci za financijsku imovinu i otplate zajmova svih lokalnih i regionalnih jedinica prosječno iznose milijardu kuna godišnje u promatranom razdoblju (tablica br. 43).

[160]https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/ financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

Najviše izdataka isplaćeno je iz proračuna gradova (gotovo 3,7 milijardi kuna), od čega se na Grad Zagreb odnosilo njih gotovo 1,5 milijardu kuna.

Tablica 43. Izdatci za financijsku imovinu i otplate kredita općina, gradova i županija u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima)

Izdatci za financijsku imovinu i otplate kredita	2014.	2015.	2016.	2017.	2018.	Ukupno
Općine	159	181	216	138	130	823
Gradovi	715	649	715	829	766	3.674
Veliki gradovi	304	229	269	327	226	1.355
Grad Zagreb	222	273	254	376	328	1.453
Županije	132	143	87	92	59	513
Ukupno	1.006	972	1.018	1.060	954	5.010
Udio u %						
Općine	15,8 %	18,6 %	21,2 %	13,1 %	13,6 %	16,4 %
Gradovi	71,1 %	66,8 %	70,3 %	78,2 %	80,2 %	73,3 %
Veliki gradovi	30,2 %	23,6 %	26,5 %	30,9 %	23,7 %	27,0 %
Grad Zagreb	22,1 %	28,1 %	24,9 %	35,5 %	34,4 %	29,0 %
Županije	13,2 %	14,7 %	8,6 %	8,7 %	6,1 %	10,2 %
Ukupno	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %	100,0 %

Izvor: Izračun autora na temelju podatka Ministarstva financija Republike Hrvatske [161]

Izdatci općina značajno osciliraju te su u 2016. godini iznosili 215,5 milijuna kuna, a samo dvije godine kasnije svega 130 milijuna kuna. Ukupni izdatci općina u promatranom razdoblju iznosili su 823 milijuna te u usporedbi s ukupnim primitcima koji su iznosili 788 milijuna kuna bilježe *višak* u iznosu 35 milijuna kuna. Slična je situacija i kod županija, jer i njihovi izdatci značajno osciliraju tijekom promatranog razdoblja, izdatci županija iznosili 513 milijuna kuna, a primitci svega 435 milijuna kuna što čini pozitivnu razliku u promatranom periodu od 78 milijuna kuna.

Primitci od zaduživanja gradova u Republici Hrvatskoj kretali su se od najviših 1,44 milijarde kuna u 2014. godini do najnižih 425,7 milijuna kuna samo godinu kasnije. Ukupno je u promatranom periodu bilo 4,4 milijarde kuna primitaka. U istom je razdoblju otplaćeno 3 milijarde kuna duga uz znatno manje godišnje oscilacije. Time je ukupan dug gradova porastao za 1,3 milijarde kuna (tablica br. 44).

[161]https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

Tablica 44. Pregled kretanja ukupnog kreditnog duga gradova u razdoblju od 2014. do 2018. godine (u 000 kuna)

Primitci od zaduživanja	2014.	2015.	2016.	2017.	2018.	Ukupno
Gradovi	1.437.534	425.648	819.552	757.329	920.034	4.360.097
Veliki gradovi	167.056	121.026	195.426	186.836	188.171	858.514
Grad Zagreb	1.185.642	192.558	443.896	366.138	558.148	2.746.382
Izdatci za otplatu glavnice primljenih kredita i zajmova						
Gradovi	548.743	499.431	552.712	724.160	709.819	3.034.863
Veliki gradovi	174.514	121.429	151.478	234.658	196.958	879.037
Grad Zagreb	219.661	238.882	253.842	372.894	328.163	1.413.441
Rast / pad ukupnog kreditnog duga						
Gradovi	888.792	-73.783	266.841	33.170	210.215	1.325.233
Veliki gradovi	-7.458	-404	43.947	-47.822	-8.787	-20.523
Grad Zagreb	965.981	-46.323	190.054	-6.756	229.985	1.332.941

Izvor: Izračun autora na temelju podatka Ministarstva financija Republike Hrvatske [162]

Nositelj tog porasta duga svih gradova je Grad Zagreb čiji je dug, u promatranom razdoblju, također porastao 1,3 milijarde kuna. Ostali su veliki gradovi smanjili svoj dug za 20,5 milijuna kuna, a ostalim gradovima ukupan je dug porastao za svega 12,8 milijuna kuna. Osim Grada Zagreba, 11 je gradova koji su u periodu od 2014. godine do 2018. godine povećali svoj kreditni dug te je njihov dug porastao za 1,55 milijardi kuna (tablica br. 45). Preostalih 13 velikih gradova smanjilo je svoje kreditne obveze za 237 milijuna kuna. Najveće smanjenje vidljivo je kod Zadra koji se u kontinuitetu razduživao te u konačnici smanjio svoj dug za 110,5 milijuna kuna odnosno na svega 6 milijuna kuna na kraju 2018. godine (tablica br. 41).

Važno je napomenuti da treba biti oprezan kod usporedbe promjena obveza za kredite i zajmove i promjena ukupnog kreditnog duga temeljenog na praćenju godišnjeg kretanja primitaka od zaduživanja te izdataka za otplatu glavnice primljenih kredita i zajmova jer može doći do određenih odstupanja koji su najčešće rezultat iskazanih tečajnih razlika za nedospjelu glavnicu kredita s ugovorenom valutnom klauzulom.

[162] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/ financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

Tablica 45. Pregled kretanja ukupnog kreditnog duga velikih gradova u razdoblju od 2014. do 2018. godine (u 000 kuna, uređenje prema silaznoj vrijednosti varijable ukupno)

Rast / pad ukupnog kreditnog duga	2014.	2015.	2016.	2017.	2018.	Ukupno
Zagreb	965.981	-46.323	190.054	-6.756	229.985	1.332.941
Velika Gorica	3.056	20.851	-3.503	22.457	18.248	61.109
Sisak	-2.438	1.543	28.779	23.978	-260	51.601
Split	19.084	17.944	18.138	-43	-28.624	26.499
Požega	-2.659	-2.712	18.480	12.889	-1.500	24.498
Dubrovnik	17.962	7.776	-9.907	-9.906	8.910	14.835
Virovitica	-1.206	-3.109	-4.708	2.194	18.791	11.961
Samobor	-4.055	-3.753	20.707	-1.151	-2.878	8.870
Pazin	14.269	-1.704	-685	-2.164	-1.453	8.262
Karlovac	9.011	8.758	-2.729	-5.065	-3.046	6.929
Osijek	-3.338	8.597	-6.792	-4.160	7.688	1.996
Kaštela	0	815	-323	-339	-146	7
Gospić	-1.005	-1.005	3.188	-899	-899	-620
Šibenik	13.949	-1.597	-1.543	-3.793	-7.989	-972
Vukovar	-746	-34	-294	-149	-168	-1.391
Vinkovci	-2.192	-548	0	0	545	-2.195
Krapina	-1.516	-1.515	-299	-64	-63	-3.457
Koprivnica	16.286	-4.714	-6.161	-18.268	8.786	-4.071
Čakovec	-3.435	-3.162	14.636	-4.381	-8.424	-4.767
Bjelovar	-5.004	2.920	-3.516	-1.648	1.519	-5.730
Pula	-9.162	-4.793	-3.775	14.759	-6.368	-9.339
Varaždin	-6.741	-3.305	-3.351	-3.416	7.238	-9.576
Slavonski Brod	-15.963	-7.316	-5.213	3.581	6.115	-18.795
Rijeka	-22.546	-11.462	-52	-30.540	-1.044	-65.645
Zadar	-19.068	-18.876	-7.129	-41.694	-23.764	-110.531
Ukupno veliki gradovi	**958.523**	**-46.727**	**234.001**	**-54.578**	**221.199**	**1.312.418**
Ukupno ostali gradovi	**-69.732**	**-27.056**	**32.840**	**87.747**	**-10.984**	**12.815**

Izvor: Izračun autora na temelju podatka Ministarstva financija Republike Hrvatske [163]

5.4. Ostali socioekonomski pokazatelji gradova u Republici Hrvatskoj

Financijski pokazatelji ne mogu u potpunosti dati uvid u stvarnu poziciju gradova, jer treba uzeti u obzir brojne druge čimbenike koji utječu na pozicioniranost gradova. Na oblikovanje krajnjih pokazatelja pozicioniranosti gradova utječu upravljačke aktivnosti čelnih ljudi gradova, zakonska regulativa te gospodarske i investicijske aktivnosti na razini gradova i na

[163] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

nacionalnoj razini. U literaturi postoje brojni pokazatelji kojima se može opisati socioekonomska pozicija gradova od kojih su najznačajniji i najčešće korišteni sljedeći gospodarski pokazatelji: bruto domaći proizvod, broj zaposlenih i nezaposlenih, izvoz, koncentracija lokalnog gospodarstva, prosječna plaća, te s njima povezani populacijski pokazatelji kao što je broj stanovnika i migracije stanovništva, stupanj obrazovanosti, indeks starenja, udio ekonomski uzdržavanog stanovništva i slični pokazatelji. Uz navedeno, posljednjih godina, sve se više razvija koncept pametnih gradova (engl. *smart city*) i pametnog urbanog razvoja pa se razvijaju pokazatelji i indeksi pomoću kojih bi se i to pratilo. Jurlina Alibegović i suradnici (2018) podijelili su model pametnoga grada u šest dimenzija:

1. p*ametno gospodarstvo (konkurentnost)*
2. *pametni građani (socijalni i ljudski kapital)*
3. *pametno upravljanje (participacija)*
4. *pametna mobilnost (promet i ICT)*[164]
5. *pametni okoliš (prirodni resursi)*
6. *pametno življenje (kvaliteta života)*.

Pokazatelji koji su korišteni također se sastoje od gospodarskih pokazatelja kao što su izdatci za istraživanja i razvoj, industrije intenzivne znanjem, patenti, poduzetništvo, međunarodni žigovi, produktivnost, zaposlenost i fleksibilnost tržišta rada, zaposleni u kreativnim industrijama te populacijski pokazatelji kao što je migracijski saldo ili broj studenata i sveučilišta. Korišteni su dodatno primjerice i pokazatelji transparentnosti upravljanja, izlaznosti na izborima, broja kulturnih sadržaja ili broja bolničkih kreveta. Svim se navedenim pokazateljima, a osobito gospodarskim te populacijskim kao i njihovom kombinacijom može učinkovito pratiti razvoj i procjenjivati stupanj razvijenosti gradova. Nažalost, najveći dio ovih podataka u Republici Hrvatskoj nije javno dostupan na razini gradova ili nije dostupan za vremensko razdoblje koje se istražuje i analizira u ovoj doktorskoj disertaciji. Primjerice, Državni zavod za statistiku objavio je prosječne plaće na razini županije za razdoblje od 2015. godine do 2017. godine. Nadalje, posljednji popis stanovništva bio je 2011. godine, a kako je od tada prošlo dosta vremena te zbog velikih migracijskih aktivnosti stanovništva nakon pristupanja Republike Hrvatske Europskoj uniji[165], podatci iz popisa stanovništva više nisu pouzdani ni vjerodostojni.

[164] engl. *Information and Communications Technology*
[165] 1. srpnja 2013. godine

5.4.1. Procjena kretanja broja stanovnika po gradovima

Procjena kretanja stanovništva rezultat je analiza Državnog zavoda za statistiku temeljenih na nekoliko različitih izvora podataka, odnosno nekoliko različitih istraživanja. Osnovu čini službeni *Popis stanovništva, kućanstava i stanova* objavljen 2011. godine kojem se pridodaje migracijski saldo, odnosno dodaju se različiti relevantni podatci kako bi se došlo do procijenjenog broja[166]. Naime, utvrđenom broju stanovnika dodaje se broj rođenih u nekom gradu ili općini (temeljem podataka iz državne matice rođenih), oduzima se broj umrlih u istom razdoblju (temeljem podataka iz državne matice umrlih) te se prikupljaju i analiziraju podatci o unutarnjim i vanjskim migracijama stanovništva (temeljem podataka Ministarstva unutarnjih poslova Republike Hrvatske). Budući da se kao službeni (kritični) trenutak popisa uzima 31. ožujka 2011. godine u 24:00h[167], procjena kretanja stanovništva obuhvaća vremensko razdoblje od navedenog datuma do datuma procjene. Prema Popisu stanovništva, kućanstava i stanova Republika Hrvatska je 2011. godine imala 4.284.889[168] stanovnika. Razdoblje promatrano u ovom radu započelo je 31.12.2013. godine na kraju dana kad je, prema procjeni, u Republici Hrvatskoj živjelo 4 246 809 stanovnika. U promatranom je razdoblju od kraja 2013. godine do kraja 2018. godine smanjen procijenjeni broj stanovnika za 171 tisuću stanovnika (tablica br. 46). Trend smanjenja broja stanovnika vidljiv je kroz cijelo navedeno razdoblje te su njime zahvaćene i općine i gradovi. Jedino je u Gradu Zagrebu vidljiv blagi porast broja stanovnika.

Tablica 46. Pregled kretanja procijenjenog broja stanovnika po općinama i gradovima u razdoblju od kraja 2013. do kraja 2018. godine (u 000)

	2013.	2014.	2015.	2016.	2017.	2018.	Rast/pad
Općine	1 237	1 225	1 209	1 191	1 169	1 154	-82
Gradovi	3 010	3 001	2 982	2 963	2 936	2 922	-88
Veliki gradovi	1 217	1 211	1 202	1 193	1 181	1 173	-44
Grad Zagreb	797	800	801	804	804	806	9
Ukupno	**4 247**	**4 225**	**4 191**	**4 154**	**4 105**	**4 076**	**-171**

Izvor: Izračun autora na temelju podatka Državnog zavoda za statistiku[169]

Razloga za depopulaciju je nekoliko, a najveći je vezan za iseljavanje radno sposobnog stanovništva nakon pristupanja Europskoj uniji te jednostavnijem pristupu tržištima rada

[166] Za definiranje ukupnog stanovništva primjenjuje se koncept uobičajenog mjesta stanovanja. *Uobičajenim mjestom stanovanja smatra se ono mjesto u kojem osoba provodi većinu svoga dnevnog odmora bez obzira na kratkotrajnu odsutnost iz tog mjesta (npr. zbog odlaska na odmor, putovanje, liječenje, u posjet i sl.)* (DZS). https://www.dzs.hr/Hrv_Eng/publication/2019/07-01-03_01_2019.htm (pristupljeno: 18. travnja 2020.).
[167] https://www.dzs.hr/Hrv/censuses/census2011/results/censusmetod.htm (pristupljeno: 18. travnja 2020.).
[168] https://www.dzs.hr/Hrv/censuses/census2011/results/censustabsxls.htm (pristupljeno: 18. travnja 2020.).
[169] http://www.dsz.hr (Stanovništvo >> Procjene stanovništva) (pristupljeno: 13. studenoga 2020.).

Njemačke, Austrije, Irske ili skandinavskih zemalja. Uz to, negativan prirodni prirast dodatan je razlog smanjivanja broja stanovnika. Naime iz godine u godinu u Republici Hrvatskoj više stanovnika umire nego se rađa te je primjerice prirodni prirast u promatranom razdoblju bio najniži u 2014. godini i iznosio je -11 273, dok je najviši bio u 2017. godini kada je 16 921 osoba više umrla nego je rođena (-16 921)[170].

5.4.2. Broj zaposlenih i nezaposlenih

Broj zaposlenih osoba trebao bi korespondirati broju osiguranika mirovinskog osiguranja koji vodi Hrvatski zavod za mirovinsko osiguranje (HZMO) te se u disertaciji broj iz navedene evidencije koristi kao broj zaposlenih osoba[171]. HZMO osiguranike dijeli u nekoliko kategorija:

1. *radnici kod pravnih osoba*
2. *obrtnici*
3. *poljoprivrednici*
4. *samostalne profesionalne djelatnosti*
5. *radnici kod fizičkih osoba*
6. *osiguranici zaposleni kod stranih osoba i u inozemstvu*
7. *osiguranici – produženo osiguranje* (HZMO).

Najznačajnije kategorije čine radnici kod pravnih osoba koji su činili 86,2 % svih osiguranika, zatim radnici zaposleni kod fizičkih osoba koji su imali udio od 6,9 %, te obrtnici s 4 % na kraju 2018. godine. Ukupan broj osiguranika, te kretanje navedenog broja u promatranom petogodišnjem razdoblju te podjela prema vrsti lokalne jedinice nalazi se u tablici br. 47.

Tablica 47. Pregled kretanja broja osiguranika mirovinskog osiguranja po općinama i gradovima u razdoblju od 2014. do 2018. godine (u 000)

	2014.	2015.	2016.	2017.	2018.	Rast/pad
Općine	173	180	186	197	206	33
Gradovi	1 224	1 233	1 254	1 278	1 300	76
Veliki gradovi	522	523	530	538	543	22
Grad Zagreb	428	430	437	443	450	22
Ukupno	**1 397**	**1 414**	**1 440**	**1 475**	**1 507**	**110**

Izvor: Izračun autora na temelju podataka Državnog zavoda za mirovinsko osiguranje[172]

[170] https://www.dzs.hr/Hrv_Eng/publication/2020/07-01-01_01_2020.htm (pristupljeno: 13. studenoga 2020.).
[171] Minimalne razlike, primjerice, mogu nastati kada su osiguranici Državnog zavoda za mirovinsko osiguranje ujedno i zaposleni u inozemstvu (npr. pomorci). Od ukupno 1,5 milijuna osiguranika na kraju 2018. godine, bilo je samo 86 osiguranika iz kategorije *zaposlenih kod stranih osoba i u inozemstvu*.
[172] Dostupno na: https://www.mirovinsko.hr/hr/statistika/890 (pristupljeno: 18. studenoga 2020.).

Iz prikazane tablice vidljiv je kontinuiran porast broja osiguranika te ukupan rast u promatranom periodu od 110 tisuća osiguranika. Najveći dio osiguranika, njih više od 86 %, dolaze s područja gradova (od toga se na Grad Zagreb odnosi 30 % svih osiguranika), a svega 13,7 % s područja općina. Veliki gradovi bez Zagreba imali su porast od 22 tisuće osiguranika u promatranom razdoblju. Bitno je napomenuti da, unatoč činjenici da su svi gradovi zabilježili porast, porast značajno oscilira od grada do grada te je cjelokupni popis velikih gradova uz porast osiguranika prikazan tablicom br. 48. Najveći postotni rast zabilježili su gradovi: Kaštela (17,5 %), Samobor (13,7 %), Dubrovnik (11,8 %), Velika Gorica (10,6 %) te Zadar (9,5 %). Najveći apsolutni porast imao je Zagreb gdje je osigurano 22 tisuće osoba više nego pet godina ranije

Tablica 48. Pregled kretanja broja osiguranika mirovinskog osiguranja velikih gradova u razdoblju od 2014. do 2018. godine (prema silaznoj vrijednosti varijable u 2018. godini)

	2014.	2015.	2016.	2017.	2018.	Rast/pad
Zagreb	428 244	429 988	437 060	442 926	450 287	22 043
Split	79 469	79 413	80 778	81 251	81 347	1 878
Rijeka	61 729	61 929	61 993	62 173	61 911	182
Osijek	46 367	46 799	47 548	47 875	48 419	2 052
Zadar	32 134	32 087	32 966	34 204	35 197	3 063
Varaždin	31 207	31 610	32 135	32 353	32 307	1 100
Pula	30 249	29 792	30 766	31 264	30 796	547
Slavonski Brod	25 068	25 106	24 994	24 837	25 791	723
Dubrovnik	21 262	21 730	22 306	23 139	23 780	2 518
Karlovac	20 833	20 948	21 277	21 419	21 419	586
Čakovec	19 896	20 061	20 183	20 601	20 531	635
Šibenik	17 481	17 698	17 600	18 295	18 315	834
Sisak	16 533	16 232	16 218	16 382	16 573	40
Koprivnica	15 834	15 890	15 938	15 905	16 160	326
Bjelovar	15 224	15 356	15 075	15 492	15 814	590
Vinkovci	14 925	15 187	15 351	15 447	15 702	777
Velika Gorica	13 583	13 633	13 776	14 415	15 028	1 445
Požega	10 785	10 805	11 125	11 186	11 210	425
Samobor	9 246	9 427	9 924	10 229	10 508	1 262
Vukovar	9 144	9 080	9 093	9 165	9 733	589
Virovitica	8 507	8 365	8 495	8 781	8 897	390
Kaštela	7 081	7 189	7 565	7 946	8 322	1 241
Krapina	5 542	5 769	5 852	5 831	5 805	263
Gospić	4 977	4 907	4 887	4 925	5 037	60
Pazin	4 468	4 245	4 452	4 582	4 712	244
Ukupno	**949 788**	**953 246**	**967 357**	**980 623**	**993 601**	**43 813**

Izvor: Izračun autora na temelju podataka Državnog zavoda za mirovinsko osiguranje[173]

[173]https://www.mirovinsko.hr/hr/statistika/890 (pristupljeno: 18. studenoga 2020.).

Ukupan broj nezaposlenih u Republicu Hrvatskoj u kontinuiranom je padu u periodu od 2014. do 2018. godine. Navedeni je trend vidljiv na svim razinama te je broj nezaposlenih u općinama smanjen za 58 tisuća, dok je u gradovima došlo do smanjenja od 116 tisuća nezaposlenih (tablica br. 49).

Tablica 49. Pregled kretanja broja nezaposlenih po općinama i gradovima u razdoblju od 2014. do 2018. godine (u 000)

	2014.	2015.	2016.	2017.	2018.	Rast/pad
Općine	107	92	77	62	49	-58
Gradovi	221	194	165	132	105	-116
Veliki gradovi	95	82	70	56	46	-49
Grad Zagreb	44	39	33	25	19	-25
Ukupno	**328**	**286**	**242**	**194**	**154**	**-175**

Izvor: Izračun autora na temelju podataka Državnog zavoda za zapošljavanje[174]

S obzirom na to da su već spomenuti trendovi vezani uz iseljavanje stanovništva vidljivi na broju stanovnika, sličan trend je vidljiv i kod broja nezaposlenih. Naime, u promatranom petogodišnjem razdoblju broj zaposlenih (mjeren brojem osiguranika mirovinskog osiguranja) porastao je za 110 tisuća, dok je u istom razdoblju broj nezaposlenih smanjen za 175 tisuća. Negativna razlika prvenstveno je rezultat iseljavanja stanovništva.

5.4.3. Indeks razvijenosti

Odmah nakon Domovinskog rata[175] započela je obnova ratom razorenih područja te povratak raseljenog i prognanog stanovništva na navedena područja. Zakoni koji su nakon rata donošeni, a primarno Zakon o područjima posebne državne skrbi[176], predstavljaju osnovu nastanka i razvoja indeksa razvijenosti te početak razdoblja mjerenja razvijenosti nekog područja. Naime, u izmjenama zakona donesenim 2002. godine, prvi se put spominje *kriterij ekonomske razvijenosti*, koji se odnosio *na utvrđivanje područja koja gospodarski zaostaju, a mjerio se pokazateljima kao što su: dohodak stanovništva, prihodi jedinica lokalne samouprave te drugim dostupnim pokazateljima (stopa nezaposlenosti, stopa zaposlenosti, opće kretanje stanovništva, stopa obrazovanosti, gustoća stanovništva i sl.)* (Zakon o područjima posebne državne skrbi).

[174] https://statistika.hzz.hr/Statistika.aspx?tipIzvjestaja=1 (pristupljeno: 18. studenoga 2020.).
[175] Domovinski je rat trajao do 1995. godine kada su prestale borbe i potpisani su mirovni sporazumi (iako je tek 1998. godine reintegrirano Podunavlje).
[176] Narodne novine (44/1996, 57/1996, 124/1997, 78/1999, 73/2000, 87/2000, 127/2000, 127/2000, 94/2001, 88/2002, 42/2005, 90/2005, 86/2008).

Nova faza u razvoju indeksa razvijenosti započela je sustavnijim pristupom regionalnom razvoju, odnosno donošenjem Zakona o regionalnom razvoju Republike Hrvatske[177] krajem 2009. godine. *Indeks razvijenosti definiran je kao kompozitni pokazatelj koji se računa kao ponderirani prosjek više osnovnih društveno-gospodarskih pokazatelja radi mjerenja stupnja razvijenosti jedinica lokalne i područne (regionalne) samouprave* (članak 3. tadašnjeg zakona). Uredbom[178] je Vlada Republike Hrvatske definirala da se indeks izračunava temeljem sljedećih pokazatelja te da pokazatelji imaju određeni udio *u ukupnoj vrijednosti indeksa razvijenosti:*

1. *stope nezaposlenosti (30 % udjela)*
2. *dohotka po stanovniku (25 % udjela)*
3. *proračunskih prihoda jedinica lokalne, odnosno područne (regionalne) samouprave po stanovniku (15 % udjela)*
4. *općega kretanja stanovništva (15 % udjela)*
5. *stope obrazovanosti (15 % udjela)* (Uredba o indeksu razvijenosti).

Dodatno, definirano je da se indeks izračunava temeljem podataka za prethodne tri godine, odnosno temeljem podataka s posljednjeg popisa stanovništva.

Završni korak u procesu determiniranja indeksa razvijenosti predstavlja razvrstavanje jedinica lokalne i područne (regionalne) samouprave koje se, prema navedenim pokazateljima, provelo krajem 2010. godine i vrijedilo je od 1. 1. 2011. godine te krajem 2013. godine i vrijedilo je od 1. 1. 2014. godine.

Jedinice lokalne samouprave razvrstane su u pet skupina:

1. *vrijednost indeksa razvijenosti manja od 50 % prosjeka Republike Hrvatske*
2. *vrijednost indeksa razvijenosti veća od 50 %, a manja od 75 % prosjeka Republike Hrvatske*
3. *vrijednost indeksa razvijenosti veća od 75 %, a manja od 100 % prosjeka Republike Hrvatske*
4. *vrijednost indeksa razvijenosti veća od 100 %, a manja od 125 % prosjeka Republike Hrvatske*
5. *vrijednost indeksa razvijenosti veća od 125 % prosjeka Republike Hrvatske* (Uredba o indeksu razvijenosti).

[177] Narodne novine (153/2009, 147/2014).
[178] Uredba o indeksu razvijenosti (Narodne novine 63/2010, 158/2013, 147/2014, 123/2017, 131/2017).

U 2014. godini u V. skupinu najrazvijenijih gradova u Republici Hrvatskoj svrstani su: Cres, Dubrovnik, Krk, Novalja, Novigrad (Istarska županija), Opatija, Poreč, Rovinj, Umag i Zagreb. Jedinice područne (regionalne) samouprave razvrstane su u 4 skupine, te je kod njihove podjele najniža skupina bila ona koja je imala indeks razvijenosti manji od 75 %.

Metodologija se promijenila 2018. godini nakon što je Vlada Republike Hrvatske prihvatila Studiju[179] kojom su utvrđene neadekvatnosti u postojećem modelu i predložen je novi model i sukladno njemu, novo razvrstavanje jedinica lokalne i područne samouprave. Prvo je izmijenjen Zakon o regionalnom razvoju Republike Hrvatske, da bi se potom donijela nova Uredba o indeksu razvijenosti[180], a potom i Odluka o razvrstavanju jedinica lokalne i područne (regionalne) samouprave prema stupnju razvijenosti[181]. Gradovi i općine se na taj način razvrstavaju u osam skupina, po četiri skupine ispodprosječno rangiranih jedinica i četiri skupine iznadprosječno rangiranih jedinica. Indeks razvijenosti, sukladno navedenoj Uredbi, *izračunava se na temelju sljedećih pokazatelja:*

1. *stope nezaposlenosti*
2. *dohotka po stanovniku*
3. *proračunskih prihoda jedinica lokalne, odnosno područne (regionalne) samouprave po stanovniku*
4. *općega kretanja stanovništva*
5. *stope obrazovanosti*
6. *indeksa starenja* (Uredba o indeksu razvijenosti).

Kako se navodi u Studiji, za izračun se koristi Balansirana z-score metoda koju su razvili autori Mazziotta i Pareto te se u znanstvenoj i stručnoj literaturi koristi pod nazivom Mazziotta-Pareto indeks. Podatci se prikupljaju iz više izvora, a najviše podatka priprema Državni zavod za statistiku. Uz njih, koriste se podatci Ministarstva financija (porezna uprava) i Hrvatskog zavoda za zapošljavanje. *Pokazatelji se izračunavaju temeljem podataka u razdoblju tri godine koje prethode postupku ocjenjivanja*, a za raspodjelu u 2018. godini korišteni su podatci iz razdoblja od 2014. do 2016. godine[182] osim za stopu obrazovanosti i indeks starenja za koje su korišteni podatci s posljednjeg popisa stanovništva (2011. godine).

[179] Denona Bogović, N.; Drezgić, S. i Čegar, S. (2017). Evaluacija postojećeg i prijedlog novog modela za izračun indeksa te izračun novog indeksa razvijenosti jedinica lokalne i područne samouprave u Republici Hrvatskoj. Cler d. o. o. Ekonomski fakultet Sveučilišta u Rijeci.
[180] Uredba o indeksu razvijenosti (Narodne novine 131/2017).
[181] Odluka o razvrstavanju jedinica lokalne i područne (Narodne novine 132/2017).
[182] https://razvoj.gov.hr/o-ministarstvu/djelokrug-1939/regionalni-razvoj/indeks-razvijenosti/vrijednosti-indeksa-razvijenosti-i-pokazatelja-za-izracun-indeksa-razvijenosti-2018/3740 (pristupljeno: 9. kolovoza 2020.).

U 2018. godini u 8., najrazvijeniju skupinu, svrstano je 34 od 128 gradova, a to su: Bakar, Biograd na Moru, Buzet, Cres, Crikvenica, Čakovec, Dubrovnik, Hvar, Kastav, Koprivnica, Krk, Labin, Makarska, Mali Lošinj, Novalja, Novigrad - Cittanova, Opatija, Pazin, Poreč - Parenzo, Pula - Pola, Rijeka, Rovinj - Rovigno, Samobor, Split, Supetar, Sveta Nedelja (Zagrebačka županija), Umag - Umago, Varaždin, Velika Gorica, Vodnjan - Dignano, Zabok, Zadar, Zagreb i Zaprešić.

5.4.4. Ocjena transparentnosti gradova

Otvorenost proračuna gradova podrazumijeva mogućnost građana da dobiju potpune, bitne, točne, pravovremene i razumljive informacije o proračunu. Institut mjeri otvorenost brojem javno[183] *objavljenih ključnih proračunskih dokumenata* (Ott, Bronić i Petrušić 2014: 1). Naime, vrlo je važno da prijedlog proračuna, ali i izvještaji o izvršavanju proračuna budu dostupni građanima kako bi mogli nadzirati proračunska trošenja, ali i uključili se u proces kreiranja budućih proračuna. Uz to, važan dokument je i vodič za građane u kojem se na jednostavan i razumljiv način široj populaciji objašnjavaju osnovne proračunske postavke odnosno osnovna struktura proračunskih prihoda i rashoda. Zakon kaže *da su javna tijela obvezna, na lako pretraživ način i u strojno čitljivom obliku, objavljivati godišnje planove, programe, strategije, upute, izvješća o radu, financijska izvješća i druge odgovarajuće dokumente* (Zakon o pravu na pristup informacijama čl. 10.). Dodatno, kaže i *da lokalne jedinice objavljuju u svom službenom glasniku proračun i projekcije, izmjene i dopune proračuna te odluku o privremenom financiranju* (Zakon o proračunu čl. 12.). Također, isti članak definira *i da se na mrežnim stranicama objavljuju polugodišnji i godišnji izvještaj o izvršenju proračuna te godišnji financijski izvještaji*. Institut za javne financije od 2013. godine analizira transparentnost ili otvorenost proračuna županija, gradova i općina u Republici Hrvatskoj. U prvom je istraživanju Institut dodjeljivao ocjene od 0 do 3, da bi u drugom istraživanju to bilo malo promijenjeno te su se ocjene kretale od 0 do 7, jer se povećao obuhvat analiziranih dokumenata. Svaki od objavljenih dokumenata nosio je po jedan bod.

U istraživanjima koja su provođena od 2015. godine do 2018. godine, analiziralo se pet najvažnijih dokumenata te su stoga ocjene bile od 0 do 5. Primjerice, u 2016. godini su istraživači Ott, Bronić i Petrušić provjeravali jesu li lokalne jedinice objavile:

1. *godišnje izvršenje proračuna za 2014.*
2. *polugodišnje izvršenje proračuna za 2015*

[183] U pravilu na web stranicama

3. *prijedlog proračuna za 2016,*
4. *izglasani proračun za 2016.*
5. *proračun za građane za 2016* (Institut za javne financije).

U tablici br. 50 nalazi se pregled kretnja ocjena velikih gradova u razdoblju od 2014. do 2018. godine.

Tablica 50. Pregled kretanja ocjena transparentnosti velikih gradova u razdoblju od 2015. do 2018. godine (uređenje prema silaznoj vrijednosti varijable u 2018. godini)

Naziv grada	2014.	2015.	2016.	2017.	2018.
Rijeka	7	5	5	5	5
Pazin	6	5	5	5	5
Osijek	5	5	5	5	5
Pula	5	5	5	5	5
Zagreb	5	5	5	5	5
Koprivnica	4	5	5	5	5
Slavonski Brod	4	5	5	5	5
Zadar	6	4	5	5	5
Dubrovnik	6	5	4	5	5
Krapina	4	4	3	5	5
Split	5	5	5	4	5
Karlovac	5	4	5	4	5
Čakovec	5	5	4	4	5
Kaštela	5	4	4	4	5
Sisak	1	0	4	3	5
Požega	1	1	3	2	5
Šibenik	5	5	5	5	4
Bjelovar	4	4	5	5	4
Samobor	3	2	3	5	4
Velika Gorica	5	4	4	4	4
Vukovar	1	4	4	4	4
Virovitica	3	3	4	4	4
Varaždin	2	4	4	3	4
Gospić	0	0	1	0	3
Vinkovci	1	0	0	4	2
Prosjek	**3,92**	**3,72**	**4,08**	**4,20**	**4,52**

Izvor: Izračun autora na temelju podataka Instituta za javne financije[184]

[184] Ott, K.; Bronić, M.; Petrušić, M. (2014). Otvorenost proračuna hrvatskih županija, gradova i općina 2013. - 2014. Newsletter br. 87. Zagreb. Institut za javne financije.
Ott, K.; Bronić, M.; Petrušić, M. (2015). Otvorenost proračuna hrvatskih županija, gradova i općina: studeni 2014. – ožujak 2015. Newsletter br. 97. Zagreb. Institut za javne financije.
Ott, K.; Bronić, M.; Petrušić, M.; Stanić, B. (2016). Otvorenost proračuna hrvatskih županija, gradova i općina: studeni 2015. – ožujak 2016. Newsletter br. 107. Zagreb. Institut za javne financije.

S obzirom na promjenu metodologije u 2015. godini, važno je napomenuti da je od tada prosječna ocjena transparentnosti velikih gradova u kontinuiranom porastu te je u zadnjoj promatranoj godini dosegnula prosječnu ocjenu od 4,52.

U prvoj godini promatranog razdoblja ocjene su se kretale od 0 (Gospić) do 7 (Rijeka) uz prosječnu ocjenu 3,92. Na skali od 1 do 5 ta bi prosječna ocjena bila 2,8. Već se u sljedećoj godini vidi značajan napredak, kada prosječna ocjena raste na 3,72.

Tijekom preostalih godina vidi se nastavak trenda rasta prosječne ocjene da bi u zadnjoj godini 16 gradova dobilo ocjenu 5, zatim 7 gradova dobilo ocjenu 4, a samo po jedan ocjenu 3 (Gospić) i ocjenu 2 (Vinkovci).

Prema ovom pokazatelju, kontinuirano je najtransparentniji Rijeka s dodijeljenom uvijek maksimalnom ocjenom.

Ott, K.; Bronić, M.; Petrušić, M.; Stanić, B. (2017). Otvorenost proračuna hrvatskih županija, gradova i općina: studeni 2016. – ožujak 2017. Newsletter. br. 112. Zagreb. Institut za javne financije.
Ott, K.; Bronić, M.; Petrušić, M.; Stanić, B. (2018). Otvorenost proračuna hrvatskih županija, gradova i općina: studeni 2017. – ožujak 2018. Newsletter br. 115. Zagreb. Institut za javne financije.
http://www.ijf.hr/transparentnost/?params_1=transparentnost (pristupljeno: 7. studenoga 2020.).

6. Metodologija istraživanja

Istraživanje doktorske disertacije usmjereno je na prikupljanje i analizu sekundarnih podataka. Sekundarni su podatci *prikupljeni i zabilježeni prije, u nekom drugom istraživanju i za neku drugu svrhu* (Marušić, Vranešević 2001: 171). To su povijesni podatci koji ne zahtijevaju kontakt s ispitanicima ili objektima istraživanja. Prednosti sekundarnih podataka očituju se višestruko nižom cijenom prikupljanja, dostupnosti, brzinom prikupljanja kao i objektivnosti. Prednost upotrebe sekundarnih podataka očituje se kroz metodološku usporedivost i reprezentativnost podataka, konzistentnu metodologiju prikupljanja koja je propisana na nacionalnoj razini (zakonima i pravilnicima) te ujednačen vremenski obuhvat podataka. Sekundarni podatci nalaze se u istraživanjima kako kreditnih rejting agencija tako i istraživačkih studija, a s ciljem utvrđivanja čimbenika koji najviše utječu na nemogućnost plaćanja obveza na vrijeme i u punom iznosu. Primjer takva pristupa korištenje je podataka za jednu promatranu godinu (Primorac, Vlah-Jerić 2017; Janda, Moreira 2016; Cohen i suradnici 2011), dok značajan broj istraživanja proučava višegodišnje vremenske serije dostupnih podataka. Holian i Joffe (2013) proučavali su u SAD-u podatke za dvogodišnje razdoblje, Navarro-Galera i suradnici (2015) četverogodišnje, Hajek i Hajkova (2009) petogodišnje, a Errais (2019) sedmogodišnje razdoblje. Nemogućnost plaćanja obveza gradova, putem podataka za dugogodišnja vremenska razdoblja odnosno razdoblja dulja od 10 godina, pratili su Palumbo i suradnici (2006), Gregori i Marattin (2017) te Gorina i suradnici (2018). Osim duljine proučavanog razdoblja, istraživački pristupi razlikuju se i u veličini analiziranog uzorka. Naime, Gregori i Marattin (2017) fokusirali su se samo na 32 lokalne jedinice koje su proglasile bankrot te je time njihov uzorak bio relativno malen u usporedbi s ostalima. Navarro-Galera i suradnici (2015) u istraživanje su uključili 148 španjolskih gradova većih od 50 000 stanovnika ili središta regija, a Holian i Joffe (2013) te Errais (2019), preko 260 gradova iz SAD-a odnosno Tunisa. Istraživački smjer kojem su obuhvaćane sve lokalne jedinice u Republici Hrvatskoj (n=556) predstavljaju studije koje su izradili Primorac i Posedel (2012) te Primorac i Vlah-Jerić (2017).

6.1. Metodologija prikupljanja podataka

Gradovi su, sukladno Pravilniku o financijskom izvještavanju u proračunskom računovodstvu, obvezni periodično predavati svoje financijske izvještaje[185], a Ministarstvo financija objedinjava godišnje izvještaje te iste objavljuje na svojim mrežnim stranicama[186]. Navedeni i javno dostupni podatci predstavljaju ključan izvor podataka za provedeno istraživanje. Radi se o podatcima o prihodima i primitcima, rashodima i izdatcima te podatcima o imovini i obvezama. Uz podatke Ministarstva financija, korišteni su i javno dostupni podatci Zavoda za statistiku (podatci o broju stanovnika), Hrvatskog zavoda za mirovinsko osiguranje (podatci o broju osiguranika), Hrvatskog zavoda za zapošljavanje (podatci o broju nezaposlenih osoba) te Instituta za javne financije (podatci o transparentnosti proračuna). Svi navedeni podatci dostupni su za istraživanjem obuhvaćeno razdoblje od 2014. do 2018. godine. Prikupljani su podatci zasebno za svaki grad koji su potom u izgrađenoj datoteci zapisani kao agregirani za velike gradove te skupni podatci za sve gradove u Republici Hrvatskoj. Podatci vezani za prihode i primitke, te rashode i izdatke prikazuju ostvarenja gradova tijekom cijele promatrane godine, dok su ostali podatci vezani za stanje na kraju promatrane, kalendarske godine. Izuzetak su samo podatci o transparentnosti gradova koje Institut za javne financije prikuplja u razdoblju od studenog do travnja obzirom na obvezu gradova za objavom nekog od proračunskih dokumenata.

6.2. Okvir uzorka

Uzorak se promatra kao podskup koji se sastoji od dijela jedinica populacije. Zaključci o populaciji često se donose na temelju rezultata uzorka, a razlog odabira uzorka umjesto cijele populacije nalazi se u financijskoj, vremenskoj i tehničkoj opravdanosti (Horvat i Mijoč 2019). Populacijom, u smislu ovoga rada, smatraju se sve jedinice lokalne i regionalne (područne) samouprave kojih u Republici Hrvatskoj ima 576. Populacija se, dakle, sastoji od svih općina, gradova (uključujući i Grad Zagreb) te svih županija. Država je znatan dio svojih ovlasti prepustila regionalnim i lokalnim razinama vlastima, a najveća odgovornost dana je gradovima. Osnovne odgovornosti definirane su zakonom, a to su: *uređenje naselja i stanovanje, prostorno i urbanističko planiranje, komunalno gospodarstvo, briga o djeci, socijalna skrb, primarna zdravstvena zaštita, odgoj i obrazovanje, kultura, tjelesna kultura i šport, zaštita potrošača,*

[185] Više u poglavlju 3.1.3.
[186] https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

zaštita i unaprjeđenje prirodnog okoliša, protupožarna i civilna zaštita te promet na svom području (člankom 19. a Zakona o lokalnoj i područnoj (regionalnoj) samoupravi). Gradovima je, kao nositeljima ključnih funkcija, država omogućila i adekvatno financiranje. Naime, 2/3 ukupnih prihoda svih regionalnih i lokalnih jedinica otpada na gradove. Gradovi su i ključni nositelji razvoja pa je preko 80 % zaduženja svih lokalnih i regionalnih jedinica u 2018. godini bilo vezano za gradove. Slijedom navedenog okvir uzorka istraživanja sastoji se od svih gradova u Republici Hrvatskoj i Grada Zagreba, odnosno 128 lokalnih jedinica. Sukladno zakonskoj definiciji kojom se dodatno opisuju i izdvajaju gradovi s većim odgovornostima koje su im dodijeljene, gradovi se dijele na male i velike. Jedan od pristupa podjele gradova prema opisanom kriteriju je broj stanovnika (17 gradova većih od 35 000 stanovnika), a drugi prethodnom pristupu pridodaje gradove središta županija ukoliko brojem stanovnika nisu označeni kao veliki gradovi (n=8). Temeljem prethodno opisanih pristupa u tablici br. 52 prikazan je dio uzorka koji se odnosi na sve velike gradove (n=25).

Tablica 51. Opis uzorka prema veličini gradova (veliki gradovi i broj stanovnika)

Veliki gradovi (25)		
Veliki gradovi veći od 35 000 stanovnika (17)		**Veliki gradovi manji od 35 000 stanovnika, sjedišta županija (8)**
Grad Zagreb (790 017)	Sisak (47 768)	Koprivnica (30 854)
Split (178 102)	Varaždin (46 946)	Vukovar (27 683)
Rijeka (128 624)	Šibenik (46 332)	Čakovec (27 104)
Osijek (108 048)	Dubrovnik (42 615)	Požega (26 248)
Zadar (75 062)	Bjelovar (40 276)	Virovitica (21 291)
Velika Gorica (63 517)	Kaštela (38 667)	Gospić (12 745)
Slavonski Brod (59 141)	Samobor (37 633)	Krapina (12 480)
Pula - Pola (57 460)	Vinkovci (35 312)	Pazin (8 638)
Karlovac (55 705)		

Izvor: Prikaz autora temeljen na podatcima s popisa stanovništva (2011. godine) Državnog zavoda za statistiku[187]

[187] www.dzs.hr (pristupljeno: 11. studenoga 2020.).

U tablici 52. prikazani su mali gradovi, kojih je prema posljednjem popisu stanovnika bilo 103, a koji su se navedenim brojem kretali od najvećeg Đakova (27 745) do najmanje Komiže (1 526). Također, važno je napomenuti da je Popovača tek 2013. godine dobila status grada.

Tablica 52. Opis uzorka prema veličini gradova (mali gradovi i broj stanovnika)

Mali gradovi (103)			
Naziv	**Naziv**	**Naziv**	**Naziv**
Đakovo (27 745)	Novi Marof (13 246)	Lepoglava (8 283)	Korčula (5 663)
Zaprešić (25 223)	Trogir (13 192)	Bakar (8 279)	Biograd na Moru (5 569)
Sinj (24 826)	Županja (12 090)	Đurđevac (8 264)	Orahovica (5 304)
Petrinja (24 671)	Popovača (11 905)	Mali Lošinj (8 116)	Buje - Buie (5 182)
Solin (23 926)	Opatija (11 659)	Čazma (8 077)	Novi Vinodolski (5 113)
Kutina (22 760)	Labin (11 642)	Rab (8 065)	Slunj (5 076)
Križevci (21 122)	Daruvar (11 633)	Prelog (7 815)	Vrbovsko (5 076)
Sveta Nedelja (18 059)	Valpovo (11 563)	Drniš (7 498)	Kraljevica (4 618)
Dugo Selo (17 466)	Pleternica (11 323)	Senj (7 182)	Novigrad/Cittanova (4 345)
Metković (16 788)	Duga Resa (11 180)	Ozalj (6 817)	Obrovac (4 323)
Poreč/Parenzo (16 696)	Crikvenica (11 122)	Ilok (6 767)	Hvar (4 251)
Našice (16 224)	Benkovac (11 026)	Pregrada (6 594)	Supetar (4 074)
Sveti Ivan Zelina (15 959)	Belišće (10 825)	Vrgorac (6 572)	Pag (3 846)
Jastrebarsko (15 866)	Imotski (10 764)	Grubišno Polje (6 478)	Skradin (3 825)
Knin (15 407)	Garešnica (10 472)	Varaždinske Toplice (6 364)	Čabar (3 770)
Omiš (14 936)	Kastav (10 440)	Otok (6 343)	Novalja (3 663)
Vrbovec (14 797)	Ploče (10 135)	Mursko Središće (6 307)	Opuzen (3 254)
Ivanić-Grad (14 548)	Beli Manastir (10 068)	Krk (6 281)	Klanjec (2 915)
Rovinj/Rovigno (14 294)	Otočac (9 778)	Kutjevo (6 247)	Cres (2 879)
Nova Gradiška (14 229)	Donji Miholjac (9 491)	Lipik (6 170)	Stari Grad (2 781)
Ogulin (13 915)	Glina (9 283)	Oroslavje (6 138)	Hrvatska Kostajnica (2 756)
Makarska (13 834)	Trilj (9 109)	Buzet (6 133)	Nin (2 744)
Ivanec (13 758)	Zabok (8 994)	Vodnjan/Dignano (6 119)	Vrlika (2 177)
Slatina (13 686)	Vodice (8 875)	Zlatar (6 096)	Vis (1 934)
Novska (13 518)	Ludbreg (8 478)	Delnice (5 952)	Komiža (1 526)
Umag - Umago (13 467)	Pakrac (8 460)	Donja Stubica (5 680)	

Izvor: Prikaz autora temeljen na podatcima s popisa stanovništva (2011. godine) Državnog zavoda za statistiku[188]

[188] Dostupno na: www.dzs.hr (pristupljeno: 11. studenoga 2020.).

6.3. Operacionalizacija varijablā

Operacionalizacija varijablā provodi se u nekoliko povezanih faza. U ovom dijelu prikazani su i pojašnjavaju se načini izračunavanja prihodovnih, rashodovnih, bilančnih te populacijskih parametara koji ujedno predstavljaju osnovu pri kreiranju zavisne varijable (6.3.1.) kao i tri skupine nezavisnih varijablā (6.3.2.).

Podlogu za kreiranje parametara čine različiti standardizirani izvještaji poput financijskog izvještaja, statističkog izvještaja i ostalih sličnih njima, a kreirani su za izvještavanje o financijskim ostvarenjima ili za praćenje kretanja određenih ključnih pokazatelja kao što su primjerice migracije stanovništva.

Izvještaj o proračunskim prihodima i rashodima, primitcima i izdatcima (PR-RAS), detaljan je izvještaj koji se sastoji od skoro tisuću različitih sintetičkih i analitičkih podataka i lokalnih i regionalnih jedinica. Svakom pojedinom podatku dodijeljena je jedinstvena brojčana šifra (AOP[189]) te račun iz računovodstvenog plana.

Koristeći navedeni izvještaj, izdvojene su najvažnije pojedinačne pozicije ili je, u drugom slučaju, više pozicija grupirano kako bi se kreirali polazišni parametri potrebni za kreiranje modela. Navedenim parametrima dodijeljena je slovna šifra i naziv, a detaljni prikaz zorno je iznesen u tablici br. 53.

Ukupni prihodi i primitci (*upp*), sastoje se od ukupnih prihoda (*up*) te primitaka od financijske imovine i zaduživanja. Osim poreznih prihoda (*ppor*) i njihovog najvažnijeg segmenta, vezanog za porez i prirez na dohodak (*pdoh*), važan dio ukupnih prihoda predstavlja i pomoć (*pom*).

Zbog velikog značaja pomoć iz Europske unije za lokalne proračune, kreiran je parametar pomoć EU (*pomEU*), koja se sastoji od zbroja pomoći koje pristižu od inozemnih vlada, pomoći od međunarodnih organizacija i institucija i tijela EU, a tu je i pomoć temeljem prijenosa EU sredstava.

[189] Automatska obrada podataka

Tablica 53. Pregled izdvojenih prihodovnih i rashodovnih parametara

Šifra*	Naziv	AOP 2018.
upp	Ukupni prihodi i primitci	629
up	Ukupni prihod	403
pp	Prihodi poslovanja	001
ppor	Prihodi od poreza	002
pdoh	Prihodi od poreza i prireza na dohodak	003
pom	Pomoć iz inozemstva i od subjekata unutar općeg proračuna	045
pomEU	Pomoć od inozemnih vlada, međunarodnih organizacija te institucija i tijela EU	046+049+066
vp	Vlastiti prihod	074+105+136
pz	Primitci od zaduživanja	474
pdkz	Primljeni dugoročni krediti, zajmovi i izdani vrijednosni papiri	449+842+843+844+845+846+848+850+851+853+855+857+858+861+863+864+866+867+868+870+872+874+876+878+880+882
uri	Ukupni rashodi i izdatci	630
ur	Ukupni rashod	404
rp	Rashod poslovanja	148
trk	Troškovi kamata	194+199
rni	Rashodi za nabavu nefinancijske imovine	341
izdat	Izdatci za financijsku imovinu i otplate zajmova	518
izdatk	Izdatci za otplatu glavnice primljenih kredita i zajmova	583
nos	Neto operativni saldo	001+289-148-341
mpp	Manjak prihoda i primitaka za pokriće u sljedećem razdoblju	636
upr	Višak raspoloživ ili manjak za pokriće u sljedećem razdoblju	-636+635

Izvor: Prikaz autora na temelju financijskih izvještaja

*šifre bilančnih pozicija (izdvojenih prihodovnih i rashodovnih parametara)

Vlastiti prihodi (*vp*), sastoje se od prihoda od imovine, prihoda od upravnih i administrativnih pristojbi, pristojbi po posebnim propisima i naknada te kazni, upravnih mjera i ostalih prihoda. Primitci od zaduživanja (*pz*) sastoje se od različitih vrsta primljenih kredita i zajmova, dok se primljeni dugoročni krediti, zajmovi i izdani vrijednosni papiri (*pdkz*) odnose na segment kredita čija je otplata ugovorena na rok dulji od 12 mjeseci, a analitički su pozicije podijeljene prema vrsti kreditora (npr. institucije i tijela EU, kreditne institucije, osiguravajuća društva, trgovačka društva u javnom sektoru, državni ili županijski proračun i sl.) te na sve vrste izdanih vrijednosnih papira (neovisno o roku dospijeća).

Iako dio financijskog *leasinga* ulazi u izračun dugoročne zaduženosti gradova (nabava opreme i vozila, ali ne osobnih automobila), iz dostupnih podataka nije moguće na prikladan način razdvojiti podatke, te stoga financijski *leasing* nije izdvojen i analiziran. Ključni financijski pokazatelji s rashodovne strane financijskih izvještaja predstavljaju dodatne parametre potrebne prilikom kreiranja modela. Ukupni rashodi i izdatci (*uri*) polazišna su kategorija, a važan su pokazatelj i ukupni rashodi (*ur*) koji se sastoje od rashoda poslovanja (*rp*) i rashoda za nabavu nefinancijske imovine (*rni*). Troškovi kamata (*trk*) sastoje se od kamata za izdane vrijednosne papire i kamata za primljene kredite i zajmove. Izdatci su prikazani putem parametra izdatci za financijsku imovinu i otplate zajmova (*izdat*) koja se sastoji od izdataka za dane zajmove i depozite, izdataka za ulaganja u vrijednosne papire, izdataka za dionice i udjele u glavnici, izdataka za otplatu glavnice za izdane vrijednosne papire te izdataka za otplatu glavnice primljenih kredita i zajmova (*izdatk*).

Neto operativni saldo (*nos*) parametar je koji je rezultat sučeljavanja prihoda i rashoda. Višak raspoloživ ili manjak za pokriće u sljedećem razdoblju (*upr*) predstavlja ukupan rezultat poslovanja te se sastoji od zbroja viška prihoda i primitaka raspoloživog u sljedećem razdoblju i manjka prihoda i primitaka za pokriće u sljedećem razdoblju, odnosno od zbroja rezultata prethodne i tekuće godine. Navedeni parametar može biti negativan ukoliko je manjak iz prethodnog razdoblja veći od viška tekuće godine ili ako je manjak tekuće godine veći od viška prethodne godine (naravno parametar može biti i pozitivan ako je situacija obrnuta). Kao zaseban parametar prikazuje se i samo kumulirani manjak odnosno manjak prihoda i primitaka za pokriće u sljedećem razdoblju (*mpp*) s obzirom na očekivanje negativnog utjecaja ove varijable na mogućnost plaćanja obveza gradova na vrijeme i u punom iznosu.

U tablici 54. prikazani su parametri primarno temeljeni na izvještaju o stanju bilance na dan izrade izvještaja (BIL), ali i na analitičkom dijelu izvještaja o proračunskim prihodima i rashodima, primitcima i izdatcima (PR-RAS) te na izvještaju o obvezama (OBVEZE). Naime, u analitičkom dijelu izvještaja PR-RAS nalaze se podatci o podjeli kredita i zajmova na kratkoročne i dugoročne odnosno na primljene kredite i zajmove te otplate glavnice primljenih kredita i zajmova. Ukupna imovina (*ui*) osnovni je bilančni parametar, a kod definiranja kratkotrajne imovine (*ki*) korištene su pozicije bilance i izvještaja o prihodima i rashodima.
Naime, kratkotrajna imovina sastoji se od proizvedene kratkotrajne imovine te financijske imovine (novca, depozita, potraživanja, vrijednosnih papira i sl.), sitnog inventara te plemenitih metala i ostalih pohranjenih vrijednosti. Zasebne varijable čine gotovina (*got*), zbroj novca u banci, blagajni i depozita (*gotd*) te potraživanja za prihode poslovanja (*potp*).

Tablica 54. Pregled izdvojenih bilančnih parametara

Šifra	Naziv	AOP 2018.
ui	Ukupna imovina	001
ki	Kratkotrajna imovina	046+047+058+063
gotd	Gotovina i depoziti	064+074
got	Gotovina	064
potp	Potraživanja za prihode poslovanja	140
uo	Ukupne obveze	163
ko	Kratkoročne obveze	164+175+(931+938+944+953+955+957+959+961+963+965)*
iz	Dug temeljem izravnog zaduživanja	176+192
okz	Obveze za kredite i zajmove	192
nok	Neto obrtni kapital	ki-ko
nfi	Neto financijska imovina	063-167-176-192
dno	Dospjele nepodmirene obveze**	037

Izvor: Prikaz autora na temelju financijskih izvještaja
* Izvještaj o proračunskim prihodima i rashodima, primitcima i izdatcima (PR-RAS)
** Izvještaj o obvezama (OBVEZE)

Na pasivnoj strani bilance gradova kreirani su parametri vezani za obveze budući da vlastiti izvori, zbog načina vrijednosnog iskazivanja nefinancijske imovine na bilančnim pozicijama[190], nisu reprezentativni i usporedivi. Stoga je osnovni parametar vezan za ukupne obveze (*uo*), a osim njega kod kreiranja modela korišten je i parametar kratkoročne obveze (*ko*). Kratkoročne obveze sastoje se od obveza za rashode poslovanja, obveza za nabavu nefinancijske imovine te otplata glavnice primljenih kratkoročnih kredita i zajmova. Pozicija otplata glavnice primljenih kratkoročnih kredita i zajmova koristi se za izračun kratkoročnih obveza iz razloga što ne postoji adekvatna bilančna podjela kredita i zajmova prema ročnosti u dostupnim financijskim izvještajima. S obzirom na način knjigovodstvene evidencije, svi iskazani primitci od kratkoročnog zaduživanja u jednoj godini predstavljaju na kraju te godine obvezu koja se mora podmiriti u roku kraćem od godine dana stoga se može smatrati ekvivalentom kratkoročnog duga.

[190] Imovina nije vrednovana po tržišnoj vrijednosti što je objašnjeno u poglavlju 5.4. pa samim time ni vlastiti izvori nisu jednakovrijedno valorizirani.

Dug temeljem izravnog zaduživanja (*iz*) sastoji se od obveza za vrijednosne papire i obveza za kredite i zajmove (*okz*) dok se neto obrtni kapital (*nok*) računa kao razlika kratkotrajne imovine i kratkoročnih obveza.

Ukupna financijska imovina umanjuje se za obveze za financijske rashode, zatim za obveze za vrijednosne papire te obveze za kredite i zajmove te se dobije parametar neto financijska imovina (*nfi*). Najvažniji parametar prikazuje dospjele nepodmirene obveze (*dno*) i njegova se vrijednost prikazuje u detaljnom izvještaju o obvezama.

Državi zavod za statistiku procjenjuje ukupan broj stanovnika u Republici Hrvatskoj (*ubs*) i broj stanovnika u svakom pojedinom gradu (*bsg*). Evidenciju o broju svojih osiguranika vodi Hrvatski zavod za mirovinsko osiguranje i u ovoj disertaciji se ovaj podatak koristi kao supstitut broju zaposlenih osoba (*bzg*). Broj nezaposlenih osoba na razini svakoga grada (*bng*) i ukupan broj nezaposlenih na razini Republike Hrvatske (*ubn*) u statističkoj je nadležnosti Hrvatskog zavoda za zapošljavanje. Ocjena transparentnosti gradova (*trans*) preuzeta je iz provedenih istraživanja Instituta za javne financije. Pregled ekonomskih parametara korištenih u modelu prikazan je u tablici 55.

Tablica 55. Pregled izdvojenih socioekonomskih parametara

Šifra	Naziv
bsg	Procijenjeni broj stanovnika nekog grada
ubs	Procijenjeni ukupni broj stanovnika RH
bzg	Broj zaposlenih u gradu
ubz	Ukupan broj zaposlenih u RH
bng	Broj nezaposlenih u gradu
ubn	Ukupan broj nezaposlenih u RH
trans	Ocjena transparentnosti

Izvor: Prikaz autora

Stavljanjem u međusobni odnos parametara iz prethodnih tablica nastaje potpuno novi set varijabli temeljem kojih se testiraju postavljene hipoteze. Navedene varijable, prema njihovoj ulozi, dijele se na zavisnu varijablu i niz nezavisnih varijablā, a njihova operacionalizacija pojašnjena je u nastavku.

6.3.1. Zavisna varijabla

Zavisna varijabla u regresijskom modelu predstavlja predmet istraživanja te se njezine varijacije objašnjavaju s pomoću drugih varijablā (Horvat i Mijoč 2019). Polazišna pretpostavka za postavljanje modela definiranje je njegove zavisne varijable. Čimbenici koji su povezani s neplaćanjem dospjelih obveza gradova predstavljaju osnovu istraživačkog problema doktorske disertacije. Dugotrajnija nemogućnost plaćanja obveza, odnosno situacija u kojoj dužnik svoje obveze ne podmiruje na vrijeme i u cijelosti dovodi do stečaja, pa se rizik da će se to dogoditi naziva kreditni rizik. Postoji čitav niz gradova koji nisu u mogućnosti plaćati svoje obveze, ali zbog zakonske regulative ne prijeti im stečaj jer se stečaj u Republici Hrvatskoj ne primjenjuje nad lokalnim jedinicama. Neovisno o tome, kako bi gradovi normalno financijski poslovali, potrebno je jasno utvrditi koji su čimbenici povezani s okolnostima u kojima gradovi ne plaćaju svoje obveze, odnosno koji utječu na smanjenje navedenog kreditnog rizika.

Posedel i Primorac (2012:334) kreirali su varijablu koja može aproksimirati kreditni rizik gradova, a koja se sastoji od omjera dospjelih nepodmirenih obveza nastalih unutar godine dana i ukupnih obveza dospjelih u toj godini. Dospjele nepodmirene obveze podatak su koji se nalazi u izvještaju o obvezama, a ukupnim obvezama dospjelim u jednoj godini smatraju se ukupni rashodi i izdatci iz izvještaja PR-RAS. Dospjele obveze mogu sadržavati dospjelu neplaćenu glavnicu kredita, dok se u nazivniku može dogoditi da izdatak za tu glavnicu nije iskazan, jer se izdatci evidentiraju po izvršenom plaćanju. Primjerice, rata kredita dospijeva npr. na dan 31.12., a plaćena je na dan 2.1. čime se ona nalazi u dospjelim obvezama, ali ne i u izdatcima iste godine. Navedena situacija može dovesti do minimalne disproporcije u prikazanim podatcima. Dakle, varijabla nemogućnost plaćanja dospjelih obveza (*default_proxy*) nastala dijeljenjem dospjelih nepodmirenih obveza iz izvještaja o obvezama (AOP 37) i ukupnih rashoda i izdataka iz izvještaja PR-RAS (AOP 630) zavisna je varijabla istraživanja (prilog br. 3). S obzirom na podatke prikazane u tablicama br. 38 i br. 39 u okviru analize imovine i obveze gradova u Republici Hrvatskoj (poglavlje 5.2.), gdje je na kraju 2018. godine bilo 684,2 milijuna kuna dospjelih obveza gradova te svega dva velika grada koja nisu imala dospjelih neplaćenih obveza, za očekivati je da će većina gradova imati iznos zavisne varijable (*default_proxy*) > 0, a dobrim se pokazateljem, osim naravno *default_proxy* = 0 što bi svim gradovima trebao biti cilj, može smatrati i svaki *default_proxy* < 0,005. Naime, dospjeli dug manji od 0,5 % ukupnih rashoda i izdataka predstavlja samo upozorenje za budućnost, ali ne i nužnu opasnost od trajne nemogućnosti izvršavanja obveza na vrijeme i u punom iznosu.

6.3.2. Nezavisne varijable

Stavljanjem u omjere različitih vrsta parametara modela nastaju nezavisne varijable. *Praktičnost primjene omjera nadoknađuje sve njihove nedostatke i mane, a upravo se praktičnost i korisnost traži na tržištu, a ne rigidne teorije i pretpostavke koje se u praksi ne mogu ispuniti. Kao takvi, omjeri su temeljna osnova analize i predviđanja stečaja i poslovnih poteškoća* (Sajter 2009: 431). Svaka nezavisna varijabla trebala bi (Horvat, Mijoč 2019: 458):

1. o*bjašnjavati varijacije u zavisnoj varijabli*
2. *imati utjecaj na analizirani istraživački problem*
3. *predviđati promjene u zavisnoj varijabli*.

Temeljem prethodnih istraživanja i dostupnih podataka kreirane su 34 nezavisne varijable koje bi mogle imati najveći utjecaj na problem istraživanja odnosno koje bi trebale objašnjavati varijacije u zavisnoj varijabli. Budući da su varijable izrazito heterogene, grupirane su u tri skupine ovisno o svojim karakteristikama i načinu utjecaja te sukladno prethodnim teorijskim spoznajama, a to su: financije i proračun, likvidnost i dug te stanovništvo (socioekonomski čimbenici).

6.3.2.1. Financije i proračun

Varijable koje se nalaze u skupini *Financije i proračun*, a prikazane u tablici br. 56, kreirane su u najvećoj mjeri kao udio pojedine vrste ili skupine prihoda i rashoda u ukupnim prihodima ili ukupnih rashodima pokazujući time snagu ili utjecaj tako izdvojenog parametra. Većina prikazanih varijablā kreću se u očekivanom rasponu od 0 do 1 (njih 11), dok se dvije varijable kreću u rasponu od -1 do 1. Udio neto operativnog salda u prihodima poslovanja (*nos_pp*) može biti negativan, kao i omjer prenesenog rezultata i ukupnih prihoda (*upr_up*) te stoga navedene varijable imaju *šire* postavljene raspone. Udio prihoda poslovanja u ukupnim prihodima (*pp_up*) kod gradova obično iznosi iznad 95 %s obzirom na to da je udio prihoda poslovanja u ukupnim prihodima svih gradova i Grada Zagreba u 2018. godini iznosio 97,6 %. Niži udio se očekuje jedino kod gradova koji su imali značajniji prihod od prodaje nefinancijske imovine u pojedinoj godini. Očekivane su velike razlike među gradovima kad je u pitanju udio prihoda od poreza u ukupnim prihodima (*ppor_up*) ili prihodima poslovanja (*ppor_pp*) te ova varijabla pokazuje kolika je ovisnost o prihodu čiju visinu određuje zakonodavac. Treba napomenuti da manji udio poreznih prihoda u ukupnim prihodima mogu imati i najrazvijeniji gradovi zbog visoke razine drugih vrsta proračunskih prihoda (komunalnog doprinosa, prihoda od zakupa poslovnih prostora i stanova, koncesije i sl.), ali i oni najmanje razvijeni, jer imaju vrlo nizak

broj zaposlenih stanovnika. Slična je situacija i s udjelom prihoda od poreza i prireza na dohodak u prihodima poslovanja (*pdoh_pp*), jer je porez na dohodak daleko najznačajniji porezni prihod gradova.

Tablica 56. Financije i proračun – izdvojene varijable

Varijabla	Opis varijable	Očekivani raspon
pp_up	Udio prihoda poslovanja u ukupnim prihodima	0 do 1
ppor_up	Udio prihoda od poreza u ukupnim prihodima	0 do 1
ppor_pp	Udio prihoda od poreza u prihodima poslovanja	0 do 1
pdoh_pp	Udio prihoda od poreza i prireza na dohodak u prihodima poslovanja	0 do 1
pom_pp	Udio pomoći u prihodima poslovanja	0 do 1
pomEU_pp	Udio pomoći od međunarodnih organizacija, inozemnih vlada te institucija i tijela EU u prihodima poslovanja	0 do 1
vp_pp	Udio vlastitih prihoda u prihodima poslovanja	0 do 1
nos_pp	Udio neto operativnog salda u prihodima poslovanja	-1 do 1
rp_ur	Udio rashoda poslovanja u ukupnim rashodima	0 do 1
rni_upp	Omjer rashoda za nabavu nefinancijske imovine i ukupnih prihoda i primitaka	0 do 1
ur_up	Omjer ukupnih rashoda i ukupnih prihoda	0 do 1
mpp_pp	Omjer prenesenog manjka prihoda i prihoda poslovanja	0 do 1
upr_up	Omjer ukupnog prenesenog rezultata i ukupnih prihoda	-1 do 1

Izvor: Prikaz autora

Udio pomoći u prihodima poslovanja (*pom_pp*) gradova, prema podatcima iz tablice br. 28, na kraju 2018. godine iznosio je 9,4 %. Činjenica je da udio pomoći u prihodima poslovanja oscilira od gradova koji gotovo da ne primaju pomoć te da je taj postotak manji od 1 % do gradova kojima pomoć predstavlja ključan segment prihoda poslovanja. Veći postotak pomoći, kod dijela gradova, može značiti i bolju apsorpciju sredstava iz nacionalnih fondova i fondova EU. Udio pomoći od međunarodnih organizacija, inozemnih vlada te institucija i tijela EU samo je segment spomenute ukupne pomoći te se u odnosu na prihode poslovanja (pomEU_pp) očekuje vrlo nizak udio, odnosno za veliku većinu gradova očekuje se da je taj postotak na razini nižoj od 5 %. Analizirajući prihode i rashode gradova u Republici Hrvatskoj (tablica br. 28), vlastiti prihodi u prihodima poslovanja (*vp_pp*) u 2018. godini iznosili su 26,6 %. Dakle, očekivano je da se navedena varijabla kreće u rasponu od 20 % do 40 % te da veći postotak znači i veću autonomiju u upravljanju financijskim potencijalom grada.

Varijabla neto operativni saldo u prihodima poslovanja (*nos_pp*) u pravilu treba biti blago pozitivna jer bi gradovi trebali uvijek imati uravnoteženu prihodovnu i rashodovnu stranu

proračuna. Blago negativan pokazatelj javlja se, primjerice, u situacijama u kojima gradovi troše prenesene viškove iz prethodnih razdoblja ili refundacije pomoći, a visoko negativan pokazatelj može ukazivati na nekontroliranu potrošnju ili visoku razinu investicija financiranu zaduživanjem.

Udio rashoda poslovanja u ukupnim rashodima (*rp_ur*) očekivano se kreću se oko 80 % pri čemu viši postotak imaju gradovi više orijentirani na tekuću potrošnju. Varijabla rashodi za nabavu nefinancijske imovine i ukupni prihod i primitci (*rni_upp*) višim postotcima prikazuje gradove koji značajnija sredstva ulažu u dugotrajnu imovinu (npr. izgradnju stambenih, poslovnih ili drugih građevinskih objekata).

Omjer ukupnih rashoda i ukupnih prihoda (*ur_up*) prikazuje uravnoteženost proračuna i u prosjeku je uvijek blizu 100 %, jer se većina gradova trudi imati uravnotežen proračun, ali postoje i gradovi čiji ukupni rashodi u nekom razdoblju nadmašuju ukupne prihode.

Dva su omjera vezana za konačni rezultat poslovanja. Prvi je vezan za preneseni manjak poslovanja koji se stavlja u odnos s prihodima poslovanja (*mpp_pp*). Ostvareni manjak prihoda i primitaka mora se u budućem periodu *pokriti* iz prihoda poslovanja stoga je važno znati koji je udio budućeg proračuna već unaprijed *potrošen*. S obzirom na podatke iz tablice br. 33 koja prikazuje 14 velikih gradova s kumuliranim manjkom većim od milijardu kuna u 2018. godini, za očekivati je da će se ovaj pokazatelj kretati u rasponu od 0 % za gradove koji su ostvarili višak do 30 % za gradove opterećene lošim poslovnim rezultatima. Drugi je pokazatelj omjer prenesenog rezultata i ukupnih prihoda (*upr_up*) koji može biti i pozitivan i negativan jer gradovi koji imaju preneseni višak prihoda i primitaka raspoloživ u prethodnom razdoblju imaju pozitivan pokazatelj, a ostali gradovi negativan pokazatelj.

6.3.2.2. Likvidnost i dug

Varijable smještene u skupinu *Likvidnost i dug* u najvećoj mjeri temelje se na parametrima iz bilance. S ciljem stvaranja potpune slike o likvidnosnoj poziciji nekoga grada ili zaduženosti odnosno stanju duga, korišteni su različiti parametri koji osim bilančnih pozicija mogu biti vezani za prihode i rashode. Detaljan pregled tako kreiranih i izdvojenih varijablā nalazi se u tablici br. 57, a varijable se kreću u različitim rasponima od onih čija obilježja mogu biti negativna (do -1) do onih koje mogu poprimiti vrijednosti veće od 1.

Tablica 57. Likvidnost i dug – izdvojene varijable

Varijabla	Opis varijable	Očekivani raspon
izdat_pp	Omjer izdataka za financijsku imovinu i otplate zajmova i prihoda poslovanja	0 do 0,1
izdatk_okz	Omjer izdataka za otplatu glavnice primljenih kredita i zajmova i obveza za kredite i zajmove	0 do 0,5
izdatk_pz	Omjer izdataka za otplatu glavnice primljenih kredita i zajmova i primitaka od zaduživanja	0 do >1
okz_uo	Udio obveza za kredite i zajmove u ukupnim obvezama	0 do 1
pdkz_rni	Omjer primljenih dugoročnih kredita, zajmova i izdanih vrijednosnih papira i rashoda za nabavu nefinancijske imovine	0 do 1
potp_pp	Omjer potraživanja za prihode poslovanja i prihoda poslovanja	0 do 1
ki_ko	Omjer kratkotrajne imovine i kratkoročnih obveza	0 do >1
nok_ur	Omjer neto obrtnog kapitala i ukupnih rashoda	-1 do >1
nfi_pp	Omjer neto financijske imovine i prihoda poslovanja	-1 do >1
got_rp	Omjer gotovine i rashoda poslovanja	0 do 1
gotd_rp	Omjer gotovine i depozita i rashoda poslovanja	0 do 1
izdat_gotd	Omjer izdataka za financ. imovinu i otplate zajmova i gotovine i depozita	0 do >1
trk_uri	Omjer troškova kamata i ukupnih rashoda i izdataka	0 do 0,1
iz_ui	Omjer duga temeljem izravnog zaduživanja i ukupne imovine	0 do 0,5
iz_pp	Omjer duga temeljem izravnog zaduživanja i prihoda poslovanja	0 do 1
iz_up	Omjer duga temeljem izravnog zaduživanja i ukupnih prihoda	0 do 1

Izvor: Prikaz autora

Omjer izdataka za financijsku imovinu i otplate zajmova i prihoda poslovanja (*izdat_pp*) pokazuje koliki dio prihoda poslovanja gradovi izdvajaju za otplate postojećih zaduženja, ali i za ulaganja u vrijednosne papire i dionice. Temeljem podataka iz tablica br. 43 i br. 28 koji ukazuju da je u 2018. godini za gradove navedeni omjer iznosio 4,4 % može se očekivati da u promatranom razdoblju gradovi prosječno izdvajaju oko 5 % prihoda poslovanja za ovu namjenu. Otplata postojećih kredita i zajmova prikazana je omjerom izdataka za otplatu glavnice primljenih kredita i zajmova i obveza za kredite i zajmove (*izdatk_okz*), gdje primjerice kod Grada Zagreba taj omjer, u promatranom petogodišnjem razdoblju varira od 15 % do 23 % sukladno podatcima iz tablica br. 41 i 44. Očekivani raspon kreće se od 0 do 50 %, jer se pretpostavlja da je 2 godine minimalno, prosječno trajanje otplate obveza za kredite i zajmove. Također, otplata postojećih kredita i zajmova može se staviti u odnos i s novim zaduživanjem (*izdatk_pz*), pri čemu pokazatelj veći od 1 sugerira smanjenje, a pokazatelj manji od 1 povećanje zaduženosti.

Gradovi, sukladno analiziranim podatcima (tablice br. 36 i 41), prosječno imaju 40 % udjela obveza za kredite i zajmove u ukupnim obvezama (*okz_uo)*, a kod nekih velikih gradova, kao što je Zagreb, taj je postotak u 2018. godini iznosio iznad 70 %. Financiranje rashoda za nabavu nefinancijske imovine zaduživanjem (*pdkz_rni*) trebalo bi se kretati u rasponu do 1. Veći omjer, s obzirom na to da se dugoročni krediti trebaju isključivo koristiti za nabavu nefinancijske imovine što bi značilo da su pojedini gradovi *povukli* sredstva od kredita na svoj račun te da će u budućnosti njime financirati investicije, a omjer bliži nuli značio bi da gradovi za ulaganje u nefinancijsku imovnu koriste druge izvore sredstava.

Kvalitetna naplata potraživanja, ali i kontinuiran rad na otpisima nenaplativih potraživanja, očituju se kroz omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*). Gradovi koji imaju visok postotak potraživanja u odnosu na prihode, mogu zbog toga imati problema s likvidnosti. Očekivani je raspon kretnja navedenog omjera od 0 do 1, s tim da nije objektivno očekivati da postoje gradovi koji nemaju evidentiranih potraživanja za prihode poslovanja odnosno da im je omjer 0.

Omjer kratkotrajne imovine i kratkoročnih obveza (*ki_ko*), odnosno koeficijent tekuće likvidnosti kod svih je gradova veći od 1 te vrijednost kratkotrajne imovine može dosegnuti i nekoliko puta veću vrijednost od vrijednosti kratkoročnih obveza. Najveći razlog leži u činjenici da je financijska imovina dio kratkotrajne imovine, a najvrjedniji dio financijske imovine su dionice i udjeli u glavnici koje gradovi imaju u svojim poduzećima (na kraju 2018. vrijednost za velike gradove iznosila je 10,2 milijarde kuna sukladno podatcima iz tablice br. 35). Razlika navedenih pokazatelja kreira neto obrtni kapital koji u kombinaciji s ukupnim rashodima (*nok_ur*) pokazuje mogu li gradovi kratkotrajnom imovinom, nakon umanjenja za kratkoročne obveze, financirati jednogodišnje rashode. Ova varijabla može biti negativna ukoliko su kratkoročne obveze veće od kratkotrajne imovine, stoga se i kreće u rasponu od -1 do >1. Velika vrijednost financijske imovine, kao i kod nezavisne varijable *ki_ko,* može vrijednost ove varijable višestruko uvećati. Omjer neto financijske imovine i prihoda poslovanja (*nfi_pp*) prikazuje snagu financijske imovine grada te je očekivana vrijednost prosjeka veća od 1. Naime, ponovno veća vrijednost udjela u gradskim poduzećima uz minimalnu zaduženost, pozitivno djeluje na navedeni omjer. Važni pokazatelji likvidnosti su i omjeri gotovine i rashoda poslovanja (*got_rp*) te gotovine i depozita i rashoda poslovanja (*gotd_rp*). Iako je očekivani raspon od 0 do 1, za očekivati je kako gradovi stanjem gotovine (i gotovine i depozita) mogu financirati dvomjesečne rashode poslovanja.

Dodatno, omjer izdataka za financijsku imovinu i otplate zajmova u odnosu s gotovinom i depozitima (*izdat_gotd*) može značajno varirati između gradova. Naime, u situaciji niskih otplata kredita i zajmova uz visoku razinu likvidnosti, navedena varijabla (*izdat_gotd*) može biti manja od 0, ali u obrnutoj situaciji u kojoj neki grad ima visoku razinu godišnjih otplata kredita i zajmova (visok udio u rashodima i izdatcima), uz nisku razinu likvidnosti varijablu može višestruko uvećati.

Pokazatelj troškova kamata u odnosu na ukupne rashode i izdatke (*trk_uri*) očekuju se u najmanjem rasponu od 0 do 10 % ukupnih rashoda i izdataka uz prosjek manji od 1 %. Zbog imovine gradova koja je desetljećima kumulirana i koja je velike vrijednosti, financiranje imovine dugom (*iz_ui*) očekuje se u rasponu od 0 do 0,5, uz vrlo nizak prosjek (niži od 5 %). Dug temeljem izravnog zaduživanja u odnosu na prihode poslovanja (*iz_pp*) ili u odnosu na ukupni prihod (*iz_up*) označava svojevrstan stupanj zaduženosti te je očekivano kretanje navedenih varijablā u rasponu od 0 do 1. Grad Zagreb primjerice je 2018. imao vrijednost nezavisne varijable *iz_up* na razini 25,5 % (sukladno analizama u tablicama br. 27 i 40.).

6.3.2.3. Stanovništvo

Varijablama smještenim u skupinu *Stanovništvo*, zajedničko je to što ih čine podatci koji nisu financijske naravi. Očekivani raspon omjera broja stanovnika (*bsg_ubs*), omjera broja zaposlenih (*bzg_ubz*) i omjera broja nezaposlenih (*bng_ubn*), prikazanih u tablici br. 58, kreće se od 0 do 50 % odnosno najviša razina ovih nezavisnih varijablā vezana je za podatke grada Zagreba, kao najvećeg grada u Republici Hrvatskoj. Ocjena transparentnosti kretala se u rasponu od 0 do 5 u razdoblju od 2015. do 2018. godine, u rasponu od 0 do 7 u 2014. godini.

Tablica 58. Stanovništvo – izdvojene varijable

Varijabla	Opis varijable	Očekivani raspon
bsg_ubs	Omjer broja stanovnika grada u ukupnom broju stanovnika RH	0 do 0,5
bzg_ubz	Omjer broja zaposlenih u gradu u ukupnom broj zaposlenih u RH	0 do 0,5
bng_ubn	Omjer broja nezaposlenih u gradu u ukupnom broj nezaposlenih u RH	0 do 0,5
trans	Ocjena transparentnosti	0-5 (7)

Izvor: Prikaz autora

6.4. Metode analize podataka

Datoteka istraživanja izrađena je temeljem podataka prikupljenih iz javno dostupnih izvora. U prethodnim dijelovima disertacije, (poglavlja 6.1. i 6.3.), opisan je postupak prikupljanja podataka te način izračuna i uvrštavanja varijablā u datoteku koja se u konačnici sastoji od 34 varijable. Podatci su analizirani primjenom računalne podrške statističko-analitičkih programa MS Excel, IBM SPSS Statistics 25 te Mplus. Program IBM SPSS Statistics primijenjen je u svim statističko-analitičkim koracima, dok je MS Excel korišten u pripremi datoteke i izračunu agregiranih nezavisnih varijablā, a Mplus u provedbi regresijske analize i analizi latentne krivulje rasta. Postavljene hipoteze zahtijevaju primjenu statističkih metoda univarijatne, bivarijatne i multivarijatne statistike. Univarijatne metode u doktorskoj disertaciji koriste se za opisivanje varijablā parametrima deskriptivne statistike s ciljem upoznavanja osnovnih karakteristika uzorka, osnovnih zakonitosti varijable te ispitivanju odnosa između parametra i njihova središta ili osi simetrije (Horvat i Mijoč, 2019). Mjere kojima se opisuju varijable su: mjere središnje tendencije, mjere disperzije, mjere asimetrije i mjera zaobljenosti.

Korelacijska analiza kao bivarijatna statistička metoda primjenjuje se pri testiranju povezanosti dviju varijablā. Mjera za opisivanje povezanosti između dviju varijablā koeficijent je korelacije kojim se mjeri intenzitet i smjer povezanosti varijablā koje se nalaze u linearnom odnosu. Kako su sve varijable mjerene na omjernoj mjernoj ljestvici primijenjen je Pearsonov koeficijent korelacije. Vrijednosti koeficijenta korelacije kreću se u intervalu od -1 do +1 gdje negativni predznaci koeficijenta ukazuju na negativnu povezanost, a pozitivni na pozitivnu povezanost dviju varijablā.

Analiza varijance primjenjuje se u testiranju razlika aritmetičkih sredina triju i više skupina te se njome testira odnos varijabiliteta između skupina podataka. *Statistički test na temelju kojeg se uz određenu razinu značajnosti donosi odluka o (ne)postojanju statistički značajne razlike između skupina u analizi varijance naziva se F-test* (Horvat i Mijoč 2019). Za visoke vrijednosti F-omjera može se zaključiti kako postoji veći varijabilitet između promatranih skupina, nego unutar skupina što istraživaču sugerira kako promatrane skupine pripadaju različitim populacijama, a samim time kako postoji statistički značajna razlika između aritmetičkih sredina analiziranih skupina. Zakonitosti promjena u varijablama uočavaju se analizom iste varijable u različitim mjerenjima kroz vrijeme te tako položeni nizovi podataka dio su analize vremenskih nizova.

Osnovni cilj vremenskih nizova promatranje je društvenih ekonomskih pojava kvalitetnim prikupljanjem podataka, pronalaženjem zakonitosti ponašanja promatranih pojava te predviđanjem njihova ponašanja u budućnosti (Horvat i Mijoč 2018: 532). Osim toga, podatci vremenskog presjeka su podatci jedne ili više varijablā prikupljeni u određenom vremenskom trenutku, a pri kombinaciji vremenskih nizova s vremenskim presjecima kreiraju se združeni podatci. *Posebna vrsta združenih podataka, u kojima se kroz različite vremenske točke pojavljuju iste vremenski presječene jedinice (iste obitelji, iste zemlje, iste regije, gradovi itd.), zovu se panel ili uzdužni (longitudinalni) podatci* (Belullo 2011: 8).

Regresijskom analizom nastoje se predvidjeti rezultati jedne varijable temeljem poznavanja rezultata druge varijable (Petz i suradnici 2012). Regresijska analiza panel-podataka predstavlja oblik analize putanje u kojoj se promatraju odnosi dviju ili više varijablā u određenom nizu vremenskih točaka mjerenja. Drugima riječima, u regresijskoj analizi panel-podataka, prate se odnosi između dviju ili više varijabli kroz vrijeme.

Regresijska analiza panel-podataka najčešće uspoređuje odnos varijablā u istoj vremenskoj točki i odnos varijablā s idućom točkom mjerenja. Za potrebe analize podataka doktorske disertacije, ispitivale su se tri vrste odnosa. Prva vrsta odnosa referira se na povezanost jedne varijable kroz promatrano vremensko razdoblje, odnosno promatra se stabilnost određene vrijednosti za jednu varijablu kroz period od pet godina. Druga vrsta promatrane povezanosti odnosi se na povezanost dviju varijabli u istoj godini, a ona govori o stupnju usklađenog variranja između nezavisnih varijablā i zavisne varijable po godinama. Možemo ih tretirati kao pet zasebnih istraživanja provedenih u svakoj od promatranih godina.

Ovaj podatak nam govori koliko je stabilan podatak o prirodi povezanost dviju varijabli (zavisne i nezavisne). Treća povezanost odnosi se na povezanost između nezavisne varijable iz prethodne godine sa zavisnom varijablom u narednoj godini. Pojašnjena povezanost može se smatrati prognostičkom, budući da se promatra koliko je nezavisna varijabla iz prethodne godine povezana sa zavisnom varijablom iz naredne godine.

Koeficijenti kojima se izražavaju povezanosti među varijablama su standardizirani beta-ponderi koji se kreću u rasponu od -1 do +1 te se interpretiraju na isti način kao i koeficijenti korelacija. Međutim, razlika između beta-pondera i koeficijenata korelacije je u tome što se korelacije odnose na povezanost između dviju varijablā bez uzimanja u obzir međuodnos s drugim varijablama.

Nasuprot tomu, beta-ponder uzima u obzir moguće kompleksne odnose između nekoliko varijablā, te nastoji njihov utjecaj uzeti u obzir prilikom izračuna povezanost dviju varijablā. Slijedom navedenog, u analizi modela ponekad je moguće zbog kompleksnih odnosa očekivati kako se među varijablama uvrštenima u model pojave vrijednost beta-pondera koji se nalaze izvan teorijski očekivanog raspona od -1 do 1.

Takav slučaj naziva se *Heywoodov* slučaj (Heywood, 1931; Kolenikov i Bolen, 2012) i često se očekuje u modelima koji promatraju određene vrijednosti tijekom određenog vremenskog intervala (tzv. longitudinalni podatci). Niža odstupanja od teorijski očekivanih vrijednosti se toleriraju, dok bi veća odstupanja ukazivala na krivo postavljeni model ili nepouzdanost indikatora korištenih u modelu.

Konačno, da bi se navedeni odnosi među varijablama u modelu mogli interpretirati, nužno je ispitati adekvatnost cijelog modela koji se određuju nizom indeksa pogodnosti koji su opisani u ovom potpogavlju nakon opisa analize latentnog rasta krivulje.

Analiza latentnog rasta krivulje statistički je postupak kojim se ispituje dinamika odnosa dviju ili više varijablā promatranih u vremenu. Minimalni broj promatranja u vremenu potreban za ovu analizu su tri vremenske točke. Cilj ove analize predvidjeti je dinamiku kretanja (engl. *slope*) u zavisnoj (kriterijskoj) varijabli te početnu ili inicijalnu vrijednost (engl. *intercept*) zavisne (kriterijske) varijable.

Procjena stope rasta i inicijalne vrijednosti provodi se putem strukturalnog modeliranja u kojem su parametri za izračun inicijalne vrijednosti fiksiraju s konstantnom vrijednosti (najčešće s vrijednosti 1), dok se parametri za izračun stope rasta fiksiraju s brojem koji odgovara vremenskim intervalima u kojem je provedeno mjerenje.

Podatci provedenog istraživanja prikupljani su u nizu od pet godina te su parametri fiksirani s vrijednostima 0, 1, 2, 3 i 4. Ovakav niz fiksiranih vrijednosti predviđa linearni trend rasta, no oblik krivulje se može mijenjati, ovisno o polazišnom modelu istraživanja. Prednost analize latentnog rasta krivulje u usporedbi s analizom trenda ili analize varijance za zavisne podatke jest u tome što je za svaki pojedini subjekta u istraživanju moguće utvrditi njegovu inicijalnu vrijednost u zavisnoj varijabli te njegovu individualnu stopu rasta.

Slijedom navedenog, jasno je vidljivo i dolazi se do zaključka kako su opisani podatci primjereni u korištenju pri testiranju i provjeravanju vrlo preciznih hipoteza kojima se pojašnjava što i kako doprinijeti većem ili manjem rastu promatrane varijable u vremenu te kakav je odnos inicijalne vrijednost s rastom varijable i slično.

Varijable koje proizlaze iz ove analize (stopa rasta i inicijalna vrijednost), predstavljaju standardizirane vrijednosti na z-skali koji se interpretiraju kao faktorski bodovi.

Nadalje, ne treba se zaboraviti i važno je za istaknuti, kako je kreiranje faktorskih bodova moguće jedino ako strukturalni model u cijelosti ima zadovoljavajuće koeficijente pristajanja modela (engl. *goodness of fit indices*).

Najčešće korišteni indeksi za ocjenu pristajanja modela su: *hi-kvadrat*, *comparative fit index* (CFI), Tucker-Lewis index (TLI), *root mean square of error of approximation* (RMSEA) i *standardized root mean square residual* (SRMR).

Granične vrijednosti za interpretaciju pogodnosti modela su vrijednosti:

1. *CFI indeksa od 0,95 do 1,00*
2. *TLI od 0,95 do 1,00*
3. *RMSEA od 0,00 do 0,08*
4. *SRMR od 0,00 do 0,08* (Hu i Bentler 1999; Steiger 2000).

Procjena parametara analizira se robusnom *maximum likelihood* procjenom, pri čemu se izračun *hi-kvadrata* računa Satorra-Bentlerovom korekcijom (Satorra i Bentler 2001).

Analize regresijskih panel-podataka i analize latentne krivulje rasta provedena je računalnim programom za statističku obradu podataka Mplus 8.1. (Muthen i Muthen, 2018).

7. Rezultati empirijskog istraživanja

Poglavlje rezultati empirijskog istraživanja podijeljeno je u tri dijela. U prvom dijelu (7.1.) prikazane su sve provedene analize i testirane hipoteze doktorske disertacije. Nakon statističkih metoda napravljena je rasprava o rezultatima istraživanja (7.2.) kao i o smjernicama za buduća istraživanja (7.3.).

7.1. Analiza čimbenika neplaćanja obveza gradova

U cilju razvoja i testiranja modela kojim se može predvidjeti nemogućnost plaćanja dospjelih obveza u gradovima Republike Hrvatske provode se brojni statistički testovi i procedure. Poglavlje sedam započinje deskriptivnom analizom zavisne i nezavisnih varijablā (7.1.1.), zatim testovima inferencijalne statistike (7.1.2. t-test nezavisnih uzoraka, 7.1.3. korelacijska analiza, 7.1.4. analiza varijance zavisnih podataka), a na samom zaključku poglavlja sedam prikazani su rezultati regresijske analize na panel-podatcima (7.1.5.) nakon koje je predložen model za predviđanje nemogućnosti plaćanja dospjelih obveza (7.1.6).

7.1.1. Deskriptivna analiza zavisne i nezavisnih varijablā

Deskriptivna analiza zavisne i nezavisnih varijablā opisuje podatke primarnog istraživanja usmjerenog na 128 gradova u Republici Hrvatskoj za razdoblje od 2014. do 2018. godine čime se broj jedinica promatranja u datoteci ogleda u 640 entiteta. Podatci za zavisnu varijablu nemogućnost plaćanja dospjelih obveza *(default_proxy)* kreću se u rasponu od 0 % do 58,7 %, odnosno postoje gradovi koji nisu imali dospjelih neplaćenih obveza (0 %), dok su najlošiji gradovi imali dospjela neplaćena dugovanja veća od 50 % svojih ukupnih rashoda i izdataka (tablica br. 59). Promatrajući prosjek varijable (8,14 %) uz standardno odstupanje od 10,9 % moguće je uočiti kako je, unatoč *širokom* rasponu varijacija, glavnina gradova ima relativno nisku razinu neplaćenih obveza u odnosu na godišnji iznos rashoda.

Tablica 59. Deskriptivna analiza zavisne varijable

Varijabla (N=640)	Minimum	Maksimum	Srednja vrijednost	Standardna devijacija	Raspon varijacija
default_proxy	0,0000	0,5866	0,0814	0,1086	0,5866

Izvor: Izračun i prikaz autora

Nezavisne varijable podijeljene u tri skupine usmjerene su prema područjima za koja postoji najveća zastupljenost u variranjima zavisne varijable.

Prva skupina *Financije i proračun* - sastoji se od 13 nezavisnih varijablā za koje je u tablici br. 60 prikazana deskriptivna statistika. U uzorku je uočeno kako se 10 varijablā prve skupine kretalo u očekivanom rasponu, dok su se preostale tri varijable kretale u većem rasponu od očekivanog.

Varijabla prihod poslovanja u odnosu na ukupne prihode (*pp_up*), kretala se u rasponu od 0,447 do 1, međutim srednja vrijednost (95,9 %) uz minimalno standardno odstupanje (6 %) ukazuje kako se gradovi u najvećoj mjeri financiraju iz prihoda poslovanja, dok se preostalih 4 % odnosilo na prihode od prodaje nefinancijske imovine. Varijabla prihodi od poreza u ukupnim prihodima (*ppor_up*), kretala su u očekivanom rasponu od 0 do 1. Grad s minimalnim udjelom poreznih prihoda u ukupnim prihodima (*ppor_up*) imao je svega 7,8 % udjela poreznih prihoda, dok je grad s najvećim udjelom imao taj omjer na visokih 84 %. Prosječno je gradovima navedeni omjer iznosio 46,3 % uz standardnu devijaciju od 14,5 %. Varijabla prihodi od poreza u prihodima poslovanja (*ppor_pp*), kretala se u sličnom rasponu varijacija kao i prethodna nezavisna varijabla. Grad s minimalnim udjelom imao je udio prihoda od poreza u prihodima poslovanja (*ppor_pp*) 8,4 %, a grad s maksimalnim udjelom imao je 84,2 %.

Srednja vrijednost varijable iznosila je 48,1 % uz standardnu devijaciju od 14,3 %. Slični su pokazatelji i za porez na dohodak koja se ubraja u najvažniju komponentu poreznih prihoda gradova. Varijabla porez na dohodak u odnosu na prihode od poreza (*pdoh_pp*), imala je raspon varijacija od minimalnih 6,62 % do maksimalnih 81,1 %, uz srednju vrijednost od 40,6 %. Rasponi varijacija kod spomenute tri nezavisne varijable temeljene na poreznim prihodima pokazuju raznolikost financiranja gradova od onih gradova koji svoje financiranje temelje na poreznim prihodima (gradovi koji su iznad prosječnih vrijednosti) do onih gradova koji u većoj mjeri koriste druge izvore financiranja (gradovi koji su ispod prosječnih vrijednosti).

Ovisnost gradova o raznim oblicima pomoći prosječno je iznosila 20,6 % uz veliki raspon od onih koji gotovo da nisu koristili pomoć (0,7 %), do onih kod kojih su imali 79,1 % udjela pomoći u prihodu poslovanja (*pom_pp*). Korištenje pomoći od međunarodnih organizacija, inozemnih vlada te institucija i tijela EU (*pomEU_pp*) unatoč velikom rasponu (od 0 % do 46,8 %), još je uvijek na niskim razinama s prosječnom srednjom vrijednosti od tek 1,6 %.

Analizom varijable vlastiti prihodi u prihodima poslovanja (*vp_pp*), može se uočiti kako vlastiti prihodi u prosjeku čine 30,2 % prihoda poslovanja te da su se kretali u rasponu od minimalnih 5,1 % do maksimalnih 75,7 %. Rashodi poslovanja u ukupnim rashodima (*rp_ur*) kretali su se u rasponu od 35,2 % do 98,4 %, uz srednju vrijednost od 78,9 % te standardnu devijaciju od 10,9 %. Gradovi su prosječno trošili 20,1 % ukupnih prihoda i primitaka na rashode za nabavu nefinancijske imovine (*rni_upp*). Raspon se kretao od grada koji gotovo da nije ulagao sredstva nabavu nefinancijske imovine u određenoj godini (1,2 %) do maksimalnih 68,1 % uz standardno odstupanje od 11 %.

Tablica 60. Deskriptivna analiza 13 nezavisnih varijablā - skupina *Financije i proračun*

Varijabla (N=640)	Minimum	Maksimum	Srednja vrijednost	Standardna devijacija	Raspon varijacija
pp_up	0,4472	1,0000	0,9594	0,0606	0,5528
ppor_up	0,0776	0,8403	0,4628	0,1446	0,7627
ppor_pp	0,0840	0,8415	0,4810	0,1426	0,7575
pdoh_pp	0,0662	0,8113	0,4064	0,1581	0,7451
pom_pp	0,0068	0,7912	0,2063	0,1527	0,7844
pomEU_pp	0,0000	0,4682	0,0157	0,0430	0,4682
vp_pp	0,0510	0,7567	0,3016	0,1226	0,7057
nos_pp	-0,8988	0,5733	0,0163	0,1433	1,4720
rp_ur	0,3524	0,9838	0,7885	0,1085	0,6315
rni_upp	0,0118	0,6808	0,2012	0,1103	0,6690
ur_up	0,5274	1,8966	0,9854	0,1361	1,3692
mpp_pp	0,0000	1,0425	0,0783	0,1278	1,0425
upr_up	-1,0400	0,5960	-0,0177	0,1848	1,6360

Izvor: Izračun i prikaz autora

Budući da neto operativni saldo, kao rezultat odnosa prihoda i rashoda, može biti negativan, udio neto operativnog salda u prihodima poslovanja (*nos_pp*), imao je očekivani raspon od -1 do 1. Deskriptivnom analizom navedene nezavisne varijable utvrđen je minimalni iznos od -89,9 %. Naime, postoji grad koji je u jednoj od analiziranih godina imao ostvaren ukupni manjak prihoda na razini 90 % ostvarenih prihoda poslovanja u toj godini. Maksimalni je pak udio ostvaren na razini 57,3 %. Ohrabruje činjenica da prosječno gradovi imaju uravnotežen odnos prihoda i rashoda s obzirom na to da je srednja vrijednost ove nezavisne varijable iznosila 1,6 % uz standardno odstupanje od 14,3 %. Dodatno u prilog uravnoteženim proračunima gradova govori i omjer ukupnih rashoda i ukupnih prihoda (*ur_up*), koji je imao srednju vrijednost od 98,5 %. Iako je očekivani raspon za ovu nezavisnu varijablu bio od 0 do 1, ipak je deskriptivna analiza pokazala širi raspon rezultata.

Naime, minimalni je omjer ukupnih rashoda u ukupnim prihodima (*ur_up*), iznosio 52,7 %, dok je maksimalni omjer iznosio 189,7 % uz standardno odstupanje od 13,6 %. Kao i kod nezavisne varijable *nos_pp*, i na varijablu *ur_up* jednako djeluje višak rashoda nad prihodima određenog grada u visini 89,7 %.

Preneseni manjak prihoda u odnosu na prihode poslovanja (*mpp_pp*), imao je srednju vrijednost u iznosu od 7,8 %, ali i raspon veći od očekivanog. Budući da neki gradovi nemaju preneseni manjak raspon kreće od 0 %, a završava na 104,3 % odnosno s gradom koji ima preneseni manjak veći od prihoda poslovanja u istoj godini. Varijabla ukupni preneseni rezultat u odnosu na ukupni prihod (*upr_up*) je zbog mogućnosti negativnog prenesenog rezultata imala očekivani raspon od -1 do 1. S obzirom na to da je maksimalni rezultat nezavisne varijable *mpp_pp* od 104,3 %, minimalni udio ukupnog prenesenog rezultata u ukupnim prihodima (*upr_up*), iznosi -104 %, a maksimalan ostvareni iznos omjera bio je 59,6 % uz srednju vrijednost od -1,8 % te standardno odstupanje od 18,5 %.

U skupini *Likvidnost i dug* - 16 je nezavisnih varijablā čija je deskriptivna analiza prikazana u tablici br. 61. Omjer izdataka za financijsku imovinu i otplate zajmova i prihoda poslovanja (*izdat_pp*), kretao se u rasponu od minimalnih 0 % do maksimalnih 48,1 % (očekivani je raspon bio od 0 % do 10 %) uz srednju vrijednost od 4,7 %. odnosno prosječno su gradovi manje od 5 % prihoda poslovanja trošili na financijsku imovinu i otplate zajmova. Analizirajući odnos izdataka za otplatu glavnice primljenih kredita i zajmova i obveza za kredite i zajmove (*izdatk_okz*) vidljiv je veliki raspon od minimalnih 0 % do maksimalnih >200 %. Ovakvi ekstremni slučajevi, kad su u pitanju maksimalne vrijednosti ove nezavisne varijable, mogu se primjerice javiti u situaciji niske zaduženosti kada glavnina duga dospijeva jednokratno. Naime, tada se u istoj godini realiziraju visoki iznosi izdataka za otplate kredita i zajmova, a zaduženost mjerena obvezama za kredite i zajmove drastično opada. Srednja vrijednost nezavisne varijable *izdatk_okz* iznosila je 56,3 % uz standardno odstupanje >200 %. Izdatci za otplatu glavnice primljenih kredita i zajmova stavljeni su u odnos i s primitcima od zaduživanja (*izdatk_pz*). Iako je srednja vrijednost 79,4 %, ponovno se javlja visoka standardna devijacija (>200 %) te vrlo veliki raspon između minimalne vrijednosti udjela od 0 % do maksimalne vrijednosti udjela >200 %. Ponovno se ekstremna situaciju može javiti ukoliko je u danoj godini realizirana velika otplata zaduženja uz minimalan iznos novih primitaka od zaduživanja. Srednja vrijednost ukazuje na činjenicu da su se u promatranom razdoblju gradovi više zaduživali, nego što su otplaćivali svoj kreditni dug.

Varijabla obveze za kredite i zajmove u ukupnim obvezama (*okz_uo*) kretala se u očekivanom rasponu od 0 do 1 te je minimum zaista iznosio 0 %, a maksimum 100 %. Srednja vrijednost u promatranom razdoblju iznosila je 40,1 % uz standardno odstupanje od 30,2 %. Omjer primljenih dugoročnih kredita i rashoda za nabavu nefinancijske imovine (*pdkz_rni*) nije se kretao u očekivanom rasponu od 0 do 1, već je maksimalan iznos udjela bio >200 %. Srednja je vrijednost iznosila 11,8 % što ukazuje na činjenicu da je samo 11,8 % rashoda za nabavu nefinancijske imovine financirano kreditnim zaduženjem. Potraživanja za prihode poslovanja u odnosu na godišnji prihod poslovanja (*potp_pp*) u promatranom razdoblju prosječno iznose 27,7 %, a važno je napomenuti da ne postoje gradovi koji nemaju tu vrstu potraživanja (minimalno 0,3 %) te da postoje i oni gradovi kod kojih je ta vrsta potraživanja nadmašila cjelogodišnji iznos prihoda (maksimalno 154 %).

Tablica 61. Deskriptivna analiza 16 nezavisnih varijablā - skupina *Likvidnost i dug*

Varijabla (N=640)	Minimum	Maksimum	Srednja vrijednost	Standardna devijacija	Raspon varijacija
izdat_pp	0,0000	0,4809	0,0467	0,0624	0,4809
izdatk_okz	0,0000	79,6870	0,5629	3,5601	79,6870
izdatk_pz	0,0000	136,3852	0,7941	6,4418	136,3852
okz_uo	0,0000	1,0000	0,4015	0,3015	1,0000
pdkz_rni	0,0000	4,3627	0,1174	0,3519	4,3627
potp_pp	0,0032	1,5398	0,2766	0,2011	1,5366
ki_ko	0,0000	358,3447	13,0321	19,8038	358,3447
nok_ur	-0,3966	5,4243	1,1638	0,8291	5,8209
nfi_pp	-0,5867	5,6341	1,1687	0,8461	6,2208
got_rp	0,0000	1,7158	0,1645	0,2011	1,7158
gotd_rp	0,0000	2,7048	0,1818	0,2515	2,7048
izdat_gotd	0,0000	1 754,9856	13,0654	113,9145	1 754,9856
trk_uri	0,0000	0,0475	0,0055	0,0068	0,0475
iz_ui	0,0000	0,2357	0,0290	0,0346	0,2357
iz_pp	0,0000	1,1409	0,1682	0,1753	1,1409
iz_up	0,0000	1,1124	0,1610	0,1680	1,1124

Izvor: Izračun i prikaz autora

Kratkotrajna je imovina, u pravilu, značajno veća od kratkoročnih obveza što potvrđuje i podatak da je srednja vrijednost udjela nezavisne varijable *ki_ko* iznosila >200 % u promatranom razdoblju, odnosno prosječno je vrijednost kratkotrajne imovine 13 puta veća od vrijednosti kratkoročnih obveza gradova. Naime, velika vrijednost financijske imovine uz nisku razinu kratkoročnih obveza, jako uvećava ovu nezavisnu varijablu. Uz navedeno, varijabla se kretala u rasponu od 0 % do >200 % maksimalno.

Budući da neto obrtni kapital može biti i negativan (u situaciji kada su kratkoročne obveze veće od kratkotrajne imovine), omjer neto obrtnog kapitala i ukupnih rashoda (*nok_ur*) kretao se u većem rasponu od očekivanog (-1 do 1), odnosno minimalni udio iznosio je -40 %, a maksimalni >200 % uz srednju vrijednost od 116,4 % te standardnu devijaciju od 82,9 % Navedena srednja vrijednost upućuje da je prosječni neto obrtni kapital gradova 16 % veći od prosječne razine ukupnih rashoda. Slično je i kod omjera neto financijske imovine u odnosu na prihode poslovanja (*nfi_pp*) koji se kretao u rasponu od minimalnih -58,7 % do maksimalnih >200 %, uz srednju vrijednost od 116,9 %. Dva sljedeća omjera vezana su za rashode poslovanja. Varijabla omjer gotovine i rashoda poslovanja (*got_rp*) imala je srednju vrijednost 16,5 % uz raspon varijacija veći od očekivanih 0 do 1. Maksimalan iznos navedene nezavisne varijable iznosio je 171,6 %. Ako se dodaju depozite u navedeni omjer, dobije se varijabla omjer gotovine i depozita i rashoda poslovanja (*gotd_rp*) te se srednja vrijednost povećava na 18,2 % uz značajno veći maksimalni iznos raspona od >200 % te standardno odstupanje od 25,2 %. Najveći je raspon u prikazanoj tablici također vezan za likvidnost, odnosno za omjer izdataka za financijsku imovinu i otplate zajmova i gotovine i depozita (*izdat_gotd*) i kretao se od 0 % do >200 %. Srednja je vrijednost iznosila 1 306 % (slično kao kod nezavisne varijable *ki_ko*), uz standardnu devijaciju >200 %. Najmanji je pak raspon vezan za udio troškova kamata u ukupnim rashodima i izdatcima (*trk_uri*) i kretao se od minimalnih 0 % do maksimalnih 4,8 %, dok je srednja vrijednost bila svega 0,55 %. Posljednja su tri omjera iz ove skupine vezana za dug temeljem izravnog zaduživanja i njegove omjere s ukupnom imovinom i prihodima. Varijabla dug temeljem izravnog zaduživanja i ukupne imovine (*iz_ui*) kretala se u rasponu od minimalnih 0 % od maksimalnih 23,6 % uz srednju vrijednost od 2,9 %. Omjer duga temeljem izravnog zaduživanja i prihoda poslovanja (*iz_pp*) imao je srednju vrijednost od 16,8 %, a omjer duga temeljem izravnog zaduživanja i ukupnog prihoda (*iz_up*) srednju vrijednost od 16,1 %. Obje su varijable imale maksimum raspona varijance veći od očekivanih 100 % (114 % i 111 %). U posljednjoj su skupini nezavisne varijable vezane za gospodarske pokazatelje i njihova deskriptivna analiza prikazana je u tablici br. 62.

Tablica 62. Deskriptivna analiza 4 nezavisne varijable - skupina *Stanovništvo*

Varijabla (N=640)	Minimum	Maksimum	Srednja vrijednost	Standardna devijacija	Raspon
bsg_ubs	0,0004	0,1978	0,0056	0,0176	0,1975
bzg_ubz	0,0002	0,3065	0,0068	0,0274	0,3062
bng_ubn	0,0002	0,1371	0,0053	0,0132	0,1369
trans	0,0000	7,0000	3,2313	1,5624	7,0000

Izvor: Izračun i prikaz autora

Udio broja stanovnika grada u ukupnom broju stanovnika kretao se do maksimalnih 19,8 %, odnosno od minimuma koji predstavlja Komižu s 1.489 stanovnika u 2017. i 2018. godini kao najmanji grad u Republici Hrvatskoj pa sve do grada Zagreba koji je najveći grad (prilog br. 4), uz srednju vrijednost udjela od 0,6 %. Udio broja zaposlenih u ukupnom broju zaposlenih kretao se do maksimalnih 30,7 %, te je srednja vrijednost iznosila 0,7 %, dok je udio broja nezaposlenih u ukupnom broju nezaposlenih imao srednju vrijednost od 0,5 %. Ocjene transparentnosti kretale su se u rasponu od 0 do 7, a srednja vrijednost u promatranom periodu iznosila je 3,23.

Deskriptivna analizu zavisne varijable kroz promatrano petogodišnje razdoblje prikazana je iz perspektive svakog pojedinog grada (tablica br. 63). Naime, sedam gradova u promatranom razdoblju nije imalo dospjelih neplaćenih obveza na kraju svake godine i to su gradovi prikazani plavom bojom u navedenoj tablici. Bitno je naglasiti da se radi o gradovima različite veličine (brojem stanovnika i veličinom proračuna) i geografske lokacije.

Tablica 63. Deskriptivna analiza zavisne varijable po gradovima
(uređenje prema uzlaznoj srednjoj vrijednosti varijable)

Naziv grada (N=5)	Minimum	Maksimum	Srednja vrijednost	Standardna devijacija
DUBROVNIK	0,0000	0,0000	0,0000	0,0000
KRAPINA	0,0000	0,0000	0,0000	0,0000
OZALJ	0,0000	0,0000	0,0000	0,0000
ROVINJ	0,0000	0,0000	0,0000	0,0000
SLUNJ	0,0000	0,0000	0,0000	0,0000
VRBOVSKO	0,0000	0,0000	0,0000	0,0000
ZABOK	0,0000	0,0000	0,0000	0,0000
IVANEC	0,0000	0,0046	0,0010	0,0020
CRIKVENICA	0,0006	0,0022	0,0011	0,0007
KARLOVAC	0,0011	0,0026	0,0015	0,0006
OGULIN	0,0005	0,0023	0,0015	0,0006
SVETA NEDJELJA	0,0007	0,0030	0,0016	0,0010
JASTREBARSKO	0,0004	0,0039	0,0018	0,0019
POREČ	0,0004	0,0056	0,0022	0,0021
VIROVITICA	0,0000	0,0111	0,0041	0,0044
OSIJEK	0,0004	0,0082	0,0044	0,0034
VELIKA GORICA	0,0002	0,0131	0,0044	0,0054
BUJE	0,0003	0,0150	0,0048	0,0063
VARAŽDINSKE TOPLICE	0,0001	0,0192	0,0048	0,0081

GLINA	0,0000	0,0233	0,0051	0,0102
NAŠICE	0,0000	0,0104	0,0057	0,0043
VRBOVEC	0,0003	0,0118	0,0063	0,0056
NOVSKA	0,0018	0,0117	0,0064	0,0046
ĐURĐEVAC	0,0022	0,0157	0,0066	0,0057
UMAG	0,0033	0,0119	0,0068	0,0035
KASTAV	0,0013	0,0153	0,0075	0,0069
BUZET	0,0026	0,0098	0,0076	0,0029
NOVIGRAD	0,0016	0,0166	0,0079	0,0064
NOVA GRADIŠKA	0,0014	0,0249	0,0081	0,0099
ZAGREB	0,0021	0,0194	0,0082	0,0072
LABIN	0,0028	0,0267	0,0086	0,0102
SVETI IVAN ZELINA	0,0000	0,0484	0,0097	0,0216
POŽEGA	0,0002	0,0251	0,0101	0,0104
ZAPREŠIĆ	0,0000	0,0382	0,0115	0,0152
BJELOVAR	0,0004	0,0461	0,0123	0,0194
PULA	0,0083	0,0160	0,0138	0,0033
DUGA RESA	0,0002	0,0435	0,0139	0,0185
SAMOBOR	0,0087	0,0191	0,0161	0,0043
HVAR	0,0009	0,0438	0,0168	0,0163
SISAK	0,0135	0,0267	0,0174	0,0056
DUGO SELO	0,0035	0,0280	0,0176	0,0098
CRES	0,0000	0,0665	0,0188	0,0275
NIN	0,0049	0,0481	0,0209	0,0163
BELI MANASTIR	0,0019	0,0539	0,0226	0,0220
VUKOVAR	0,0003	0,0557	0,0240	0,0263
NOVALJA	0,0128	0,0335	0,0247	0,0088
SINJ	0,0068	0,0631	0,0250	0,0239
KRALJEVICA	0,0000	0,0675	0,0262	0,0358
IVANIĆ-GRAD	0,0073	0,0549	0,0271	0,0186
POPOVAČA	0,0000	0,0968	0,0286	0,0399
SPLIT	0,0229	0,0394	0,0305	0,0065
DONJA STUBICA	0,0092	0,0406	0,0307	0,0134
KAŠTELA	0,0088	0,0818	0,0319	0,0325
PREGRADA	0,0112	0,0513	0,0346	0,0189
MURSKO SREDIŠĆE	0,0258	0,0752	0,0366	0,0216
ŽUPANJA	0,0118	0,0660	0,0381	0,0222
BAKAR	0,0000	0,1901	0,0389	0,0845
KUTINA	0,0256	0,0592	0,0410	0,0155
OROSLAVJE	0,0148	0,0612	0,0416	0,0188
BELIŠĆE	0,0282	0,0519	0,0424	0,0103

LEPOGLAVA	0,0050	0,0789	0,0439	0,0319
GOSPIĆ	0,0001	0,0867	0,0441	0,0406
ĐAKOVO	0,0005	0,1212	0,0458	0,0496
SKRADIN	0,0309	0,0770	0,0458	0,0184
SLAVONSKI BROD	0,0012	0,0929	0,0466	0,0439
STARI GRAD	0,0160	0,0819	0,0478	0,0273
SLATINA	0,0148	0,0769	0,0500	0,0306
MAKARSKA	0,0468	0,0586	0,0532	0,0043
TRILJ	0,0167	0,1501	0,0547	0,0543
SOLIN	0,0204	0,1039	0,0548	0,0315
DARUVAR	0,0061	0,1138	0,0591	0,0483
VINKOVCI	0,0000	0,1056	0,0593	0,0401
KRK	0,0012	0,2759	0,0608	0,1203
KOPRIVNICA	0,0310	0,1004	0,0629	0,0338
PAKRAC	0,0000	0,1952	0,0668	0,0767
SENJ	0,0306	0,0935	0,0675	0,0258
KRIŽEVCI	0,0063	0,1400	0,0696	0,0606
NOVI MAROF	0,0264	0,1213	0,0733	0,0401
KOMIŽA	0,0237	0,1577	0,0745	0,0632
VODICE	0,0527	0,0927	0,0745	0,0149
KLANJEC	0,0269	0,1318	0,0760	0,0395
KORČULA	0,0243	0,1521	0,0775	0,0490
GRUBIŠNO POLJE	0,0513	0,1034	0,0780	0,0209
PETRINJA	0,0000	0,2121	0,0788	0,0854
ČAKOVEC	0,0497	0,1058	0,0809	0,0241
OPATIJA	0,0000	0,3832	0,0835	0,1682
OPUZEN	0,0439	0,1218	0,0836	0,0284
PAZIN	0,0726	0,1000	0,0845	0,0098
GAREŠNICA	0,0004	0,2485	0,0862	0,0963
IMOTSKI	0,0202	0,1293	0,0943	0,0448
DRNIŠ	0,0544	0,1459	0,0954	0,0396
LIPIK	0,0238	0,1803	0,0963	0,0609
ČAZMA	0,0762	0,1145	0,0995	0,0159
VIS	0,0744	0,1245	0,1010	0,0230
PRELOG	0,0310	0,1895	0,1012	0,0782
LUDBREG	0,0369	0,1634	0,1023	0,0564
KUTJEVO	0,0065	0,2480	0,1030	0,0961
PAG	0,0494	0,1965	0,1068	0,0600
MALI LOŠINJ	0,0376	0,1920	0,1111	0,0562
VRLIKA	0,0801	0,2292	0,1235	0,0616
BENKOVAC	0,0265	0,2055	0,1266	0,0689

METKOVIĆ	0,0832	0,2168	0,1287	0,0517
VARAŽDIN	0,1008	0,1909	0,1338	0,0425
ZADAR	0,1226	0,1605	0,1382	0,0145
OBROVAC	0,0413	0,3409	0,1401	0,1175
ZLATAR	0,0419	0,3089	0,1430	0,1073
VODNJAN	0,1224	0,1599	0,1434	0,0151
ŠIBENIK	0,0958	0,2417	0,1701	0,0593
DELNICE	0,1359	0,2196	0,1729	0,0372
VRGORAC	0,1569	0,1967	0,1786	0,0149
RAB	0,1242	0,2669	0,1801	0,0628
VALPOVO	0,1514	0,2048	0,1816	0,0206
PLETERNICA	0,0356	0,3278	0,1861	0,1198
KNIN	0,0599	0,3189	0,2082	0,1099
ILOK	0,0973	0,3235	0,2258	0,0854
RIJEKA	0,1743	0,2786	0,2316	0,0417
NOVI VINODOLSKI	0,1100	0,2953	0,2420	0,0796
DONJI MIHOLJAC	0,0450	0,4139	0,2691	0,1559
PLOČE	0,1814	0,3818	0,2824	0,0796
OMIŠ	0,2279	0,4718	0,3125	0,1073
TROGIR	0,0535	0,4522	0,3145	0,1614
BIOGRAD NA MORU	0,2390	0,4175	0,3227	0,0830
ČABAR	0,0795	0,5866	0,3265	0,2123
HRVATSKA KOSTAJNICA	0,2422	0,4769	0,3410	0,0886
OTOK	0,2853	0,3970	0,3492	0,0574
OTOČAC	0,2667	0,5729	0,3599	0,1261
ORAHOVICA	0,0162	0,5318	0,3671	0,2103
SUPETAR	0,2979	0,4772	0,3819	0,0851
UKUPNO	0,0000	0,5866	0,0814	0,1086

Izvor: Izračun i prikaz autora

Crvenom bojom označena su četiri, brojem stanovnika, najveća grada u Republici Hrvatskoj. Na prikazanoj ljestvici od najmanjeg iznosa srednje vrijednosti zavisne varijable do najvećeg, Osijek se nalazi na 16. mjestu sa srednjom vrijednosti od 0,44 %. Grad Zagreb je na 30. mjestu s 0,82 % prosječnog udjela dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima. Nešto malo niže na ljestvici, na mjestu 51. nalazi se Split sa srednjom vrijednosti zavisne varijable od 3,05 %. Daleko najlošiji pokazatelj zavisne varijable ima Rijeka jer se nalazi na 116. mjestu s visokih 23,16 %. Na samom su dnu liste gradovi označeni plavom bojom kojima se srednja vrijednost navedenog udjela kretala u rasponu od 32,7 % (Čabar) do 38,19 % (Supetar). Važno je napomenuti da su se kod Čabra, Otočca i Orahovice vrijednosti zavisne varijable kretale u nekim godinama i iznad 50 %.

7.1.2. T-test nezavisnih uzoraka

Ispitivanje nemogućnosti plaćanja dospjelih obveza uzorkom je usmjereno na sve gradove Republike Hrvatske dok teorijska promišljanja podupiru hipotezu kako se gradovi razlikuju prema nemogućnosti plaćanja dosjelih obveza s obzirom na određene karakteristike U doktorskoj disertaciji skupina varijablā koje se odnose na gospodarstvo zbog niskog stupnja prikupljanja podatka te slabijeg intenziteta i kontinuiteta objavljivanja podataka donosi i socioekonomske varijable. Veličina gradova smatra se jednom od prediktivnih varijablā za koju se pretpostavlja da postoji razlika između manjih i većih gradova (H4). Za testiranje H4 hipoteze prema kojoj veliki gradovi imaju statistički značajno manju izloženost za nemogućnost plaćanja od ostalih gradova u Republici Hrvatskoj primjenjuje se t-test nezavisnih uzoraka. U provedbi ovog testa gradovi se dijele na male i velike prema kriteriju opisanom u poglavlju 6.2.

Tablica 64. T-test nezavisnih uzoraka za zavisnu varijablu prema veličini gradova

	n	**Srednja vrijednost**	**Standardna devijacija**	**Standardna pogreška aritmetičke sredine**	**Pokazatelji t-testa**
Veliki gradovi (25 gradova)	125	0,0492	0,064	0,006	t = -5,219 df = 346,511 p < 0,001
Manji gradovi (103 gradova)	515	0,0892	0,116	0,005	

Izvor: Izračun i prikaz autora

Rezultati provedenog t-testa nezavisnih uzoraka pokazali su kako se nemogućnost plaćanja dospjelih obveza (*default_proxy*) statistički značajno razlikuje između malih i velikih gradova (t = -5,219, df = 346,511, p < 0,001). Veliki gradovi imaju statistički značajnu manju prosječnu vrijednost dospjelih neplaćenih obveza (aritmetička sredina = 0,049, st. devijacija = 0,064) nego manji gradovi (aritmetička sredina = 0,089, st. devijacija = 0,116). Prema Cohenu (1988) veličina učinka potvrđene razlike srednje je veličine (0,560).

Slijedom iznesenih rezultata prikazano je dovoljno dokaza za ne odbacivanje H4 hipoteze prema kojoj veliki gradovi zaista imaju statistički značajno manju izloženost za nemogućnost plaćanja dospjelih obveza od ostalih gradova u Republici Hrvatskoj.

7.1.3. Korelacijska analiza

Korelacijskom analizom ispitivala se statistička povezanost između nezavisnih varijablā i zavisne varijable. Korelacijska analiza provedena je prema skupinama nezavisnih varijablā (tri

skupine) te je temeljem visine koeficijenta korelacije, njegove statističke značajnosti i sadržajne smislenosti (npr. preklapanje izračuna agregiranih nezavisnih varijablā te očekivanja multikolinearnosti u podatcima) u tablici br. 65 zapisan odabir varijablā za modeliranje i testiranje postavljenih hipoteza. Korelacijska analiza provedena je za prvu skupinu nezavisnih varijablā (13 varijablā), koje se odnose na skupinu *Financije i proračun.* U tablici br. 65 zapisani su rezultati koeficijenata korelacije kojima se uspoređivala povezanost svake od nezavisnih varijablā skupine *Financije i proračun* s vrijednostima zavisne varijable za svaku pojedinu godinu.

Tablica 65. Korelacija - skupina *Financije i proračun*

Nezavisne varijable		**Zavisna varijabla - Omjer dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima**				
		(1)	(2)	(3)	(4)	(5)
Udio prihoda poslovanja u ukupnim prihodima (*pp_up*)	r	0,026	0,048	-0,112	0,009	-0,043
	p	0,772	0,592	0,207	0,923	0,632
	n	128	128	128	128	128
Udio prihoda od poreza u ukupnim prihodima (*ppor_up*)	r	-0,209*	-0,211*	-0,227**	-0,270**	-0,164
	p	0,018	0,017	0,010	0,002	0,064
	n	128	128	128	128	128
Udio prihoda od poreza u prihodima poslovanja (*ppor_pp*)	r	-0,239**	-0,227**	-0,215*	-0,277**	-0,169
	p	0,007	0,010	0,015	0,002	0,057
	n	128	128	128	128	128
Udio prihoda od poreza i prireza na dohodak u prihodima poslovanja (*pdoh_pp*)	r	-0,230**	-0,210*	0-,209*	-0,247**	-0,156
	p	0,009	0,017	0,018	0,005	0,079
	n	128	128	128	128	128
Udio pomoći u prihodima poslovanja (*pom_pp*)	r	0,173	0,138	0,093	0,191*	0,044
	p	0,051	0,120	0,295	0,031	0,625
	n	128	128	128	128	128
Udio pomoći od međunarodnih organizacija, inozemnih vlada te institucija i tijela EU u prihodima poslovanja (*pomEU_pp*)	r	0,065	-0,013	0,309**	0,089	0,070
	p	0,467	0,885	0,000	0,320	0,435
	n	128	128	128	128	128
Udio vlastitih prihoda u prihodima poslovanja (*vp_pp*)	r	0,104	0,070	0,128	0,089	0,131
	p	0,244	0,434	0,150	0,320	0,142
	n	128	128	128	128	128
Udio neto operativnog salda u prihodima poslovanja (*nos_pp*)	r	0,145	0,011	-0,058	-0,053	0,003
	p	0,102	0,904	0,518	0,553	0,975
	n	128	128	128	128	128
Udio rashoda poslovanja u ukupnim rashodima (*rp_ur*)	r	0,064	0,057	0,100	0,008	-0,023
	p	0,476	0,520	0,259	0,930	0,794
	n	128	128	128	128	128
	r	-0,080	-0,029	-0,065	0,009	0,027

Omjer rashoda za nabavu nefinancijske imovine i ukupnih prihoda i primitaka (*rni_upp*)	p	0,371	0,743	0,468	0,919	0,763
	n	128	128	128	128	128
Omjer ukupnih rashoda i ukupnih prihoda (*ur_up*)	r	-0,153	-0,009	0,069	0,053	-0,009
	p	0,086	0,922	0,439	0,551	0,916
	n	128	128	128	128	128
Omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*)	r	0,663**	0,757**	0,752**	0,743**	0,404**
	p	0,000	0,000	0,000	0,000	0,000
	n	128	128	128	128	128
Omjer ukupnog prenesenog rezultata i ukupnih prihoda (*upr_up*)	r	-0,557**	-0,552**	-0,589**	-0,646**	-0,347**
	p	0,000	0,000	0,000	0,000	0,000
	n	128	128	128	128	128

Izvor: Izračun i prikaz autora

* Korelacija statistički značajna na razini značajnosti od 5 %,
** Korelacija statistički značajna na razini značajnosti od 1 %;
r – Pearsonov koeficijent korelacije, p – koeficijent značajnosti; (1) – default_proxy 2014, (2) – default_proxy 2015, (3) – default_proxy 2016, (4) – default_proxy 2017, (5) – default_proxy 2018.

Postupak odabira varijablā koje su korištene u testiranju modela za nemogućnost plaćanja dospjelih obveza uključuju analizu koeficijenta značajnosti (p) te visinu koeficijenta korelacije (r). Za pet varijabli zabilježena je statistički značajna povezanost. U postupku odabira uspoređivale su se tri varijable (*pp_up, ppor_pp i pdoh_pp*) koje imaju statistički značajan koeficijent korelacije te je izdvojen i označen samo pokazatelj *ppor_pp* koji sa zavisnom varijablom ima najveću negativnu korelaciju uz prikladnu razinu statistički značajne povezanosti. Ostale dvije varijable (*pp_up i pdoh_pp*) nisu izabranes obzirom na to da je metodologija izračuna slična s metodologijom izračuna odabrane varijable te je zbog pretpostavke o multikolinearnosti odabrana samo jedna varijabla i to ona s najvećim koeficijentom korelacije za sve promatrane godine. Također, omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*) i zavisne varijable pozitivno korelira uz statistički značajnu povezanost te je navedeni pokazatelj također izdvojen i označen. Omjer ukupnog prenesenog rezultata i ukupnih prihoda (*upr_up*) nije izabran zbog sličnosti u metodologiji s prethodnim pokazateljem te u odnosu na njega ima i manju vrijednost koeficijenta korelacije.

Preostale nezavisne varijable nemaju statistički značajnu korelaciju sa zavisnom varijablom. Korelacijska analiza provedena je i za drugu skupinu ¨Likvidnost i dug¨ nezavisnih varijablā (16 varijablā). U tablici br. 66 zapisani su rezultati koeficijenta korelacije kojima je uspoređena povezanost svake od 16 nezavisnih varijablā s vrijednostima zavisne varijable za svaku od analiziranih godina.

Tablica 66. Korelacija - *Likvidnost i dug*

Nezavisne varijable		Zavisna varijabla - Omjer dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima				
		(1)	(2)	(3)	(4)	(5)
Omjer izdataka za financijsku imovinu i otplate zajmova i prihoda poslovanja (*izdat_pp*)	r	-0,025	0,138	-0,011	0,128	-0,085
	p	0,780	0,121	0,905	0,149	0,339
	n	128	128	128	128	128
Omjer izdataka za otplatu glavnice primljenih kredita i zajmova i obveza za kredite i zajmove (*izdatk_okz*)	r	-0,014	0,086	-0,050	0,233**	0,284**
	p	0,874	0,335	0,574	0,008	0,001
	n	128	128	128	128	128
Omjer izdataka za otplatu glavnice primljenih kredita i zajmova i primitaka od zaduživanja (*izdatk_pz*)	r	0,112	0,198*	0,035	0,170	-0,051
	p	0,206	0,025	0,698	0,055	0,571
	n	128	128	128	128	128
Udio obveza za kredite i zajmove u ukupnim obvezama (*okz_uo*)	r	-0,172	-0,326**	-0,172	-0,252**	-0,257**
	p	0,052	0,000	0,052	0,004	0,003
	n	128	128	128	128	128
Omjer primljenih dug. kredita, zajmova i izdanih vrijednosnih papira i rashoda za nabavu nefinancijske imovine (*pdkz_rni*)	r	-0,041	0,086	0,066	-0,144	-0,065
	p	0,644	0,336	0,462	0,104	0,465
	n	128	128	128	128	128
Omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*)	r	0,166	0,257**	0,323**	0,232**	0,145
	p	0,061	0,003	0,000	0,008	0,103
	n	128	128	128	128	128
Omjer kratkotrajne imovine i kratkoročnih obveza (*ki_ko*)	r	-0,232**	-0,199*	-0,275**	-0,386**	-0,142
	p	0,008	0,024	0,002	0,000	0,109
	n	128	128	128	128	128
Omjer neto obrtnog kapitala i ukupnih rashoda (*nok_ur*)	r	0,060	0,051	0,057	0,091	0,061
	p	0,498	0,569	0,525	0,309	0,493
	n	128	128	128	128	128
Omjer neto financijske imovine i prihoda poslovanja (*nfi_pp*)	r	0,045	0,150	0,153	0,189*	0,132
	p	0,614	0,091	0,085	0,033	0,139
	n	128	128	128	128	128
Omjer gotovine i rashoda poslovanja (*got_rp*)	r	-0,062	-0,044	-0,198*	-0,205*	-0,098
	p	0,485	0,621	0,025	0,020	0,269
	n	128	128	128	128	128
Omjer gotovine i depozita i rashoda poslovanja (*gotd_rp*)	r	0,133	0,171	-0,021	-0,128	-0,103
	p	0,133	0,053	0,817	0,150	0,247
	n	128	128	128	128	128
Omjer izdataka za financ. imovinu i otplate zajmova i gotovine i depozita (*izdat_gotd*)	r	-0,036	0,012	0,206*	0,259**	-0,014
	p	0,687	0,889	0,020	0,003	0,877
	n	128	128	128	128	128

Udio troškova kamata i ukupnih rashoda i izdataka (*trk_uri*)	r	-0,016	-0,032	0,151	0,115	-0,156
	p	0,854	0,722	0,089	0,197	0,078
	n	128	128	128	128	128
Omjer duga temeljem izravnog zaduživanja i ukupne imovine (*iz_ui*)	r	0,067	-0,106	-0,064	-0,093	-0,136
	p	0,450	0,236	0,473	0,299	0,125
	n	128	128	128	128	128
Omjer duga temeljem izravnog zaduživanja i prihoda poslovanja (*iz_pp*)	r	0,079	-0,026	0,086	-0,019	-0,133
	p	0,372	0,774	0,332	0,835	0,134
	n	128	128	128	128	128
Omjer duga temeljem izravnog zaduživanja i ukupnih prihoda (*iz_up*)	r	0,081	-0,019	0,093	-0,019	-0,138
	p	0,364	0,827	0,298	0,831	0,120
	n	128	128	128	128	128

Izvor: Izračun i prikaz autora

*Korelacija statistički značajna na razini značajnosti od 5 %,
** Korelacija statistički značajna na razini značajnosti od 1 %,
r – Pearsonov koeficijent korelacije, p – koeficijent značajnosti; (1) – default_proxy 2014, (2) – default_proxy 2015, (3) – default_proxy 2016, (4) – default_proxy 2017, (5) – default_proxy 2018.

U tablici br. 66 izdvojene su i označene četiri nezavisne varijable kod kojih postoji statistički značajna povezanost sa zavisnom varijablom. Tri varijable imaju negativan smjer povezanosti, a to su: udio obveza za kredite i zajmove u ukupnim obvezama (*okz_uo*), omjer kratkotrajne imovine i kratkoročnih obveza (*ki_ko*) te omjer gotovine i rashoda poslovanja (*got_rp*), dok omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*) ima pozitivan smjer povezanosti sa zavisnom varijablom.

Preostale nezavisne varijable ove skupine nemaju statistički značajnu korelaciju sa zavisnom varijablom.

Korelacijska analiza za treću skupinu *Stanovništvo* nezavisnih varijablā (4 varijable), prikazana je u tablici br. 67 gdje su zapisani rezultati koeficijenta korelacije kojima je uspoređena povezanost svake od četiri nezavisne varijable s vrijednostima zavisne varijable za svaku od analiziranih godina.

Tablica 67. Korelacija - *Stanovništvo*

Nezavisne varijable		Zavisna varijabla - Omjer dospjelih nepodmirenih obveza u uk. rashodima i izdatcima				
		(1)	(2)	(3)	(4)	(5)
Omjer broja stanovnika grada u ukupnom broju stanovnika RH (*bsg_ubs*)	r	-0,110	-0,091	-0,085	-0,090	-0,057
	p	0,215	0,307	0,338	0,315	0,520
	n	128	128	128	128	128
Omjer broja zaposlenih u gradu u ukupnom broj zaposlenih u RH (*bzg_ubz*)	r	-0,099	-0,082	-0,074	-0,079	-0,047
	p	0,264	0,360	0,409	0,374	0,601
	n	128	128	128	128	128
Omjer broja nezaposlenih u gradu u ukupnom broj nezaposlenih u RH (*bng_ubn*)	r	-0,121	-0,096	-0,093	-0,094	-0,067
	p	0,173	0,280	0,294	0,289	0,450
	n	128	128	128	128	128
Ocjena transparentnosti (*trans*)	r	-0,204*	-0,159	-0,171	-0,306**	-0,189*
	p	0,021	0,074	0,054	0,000	0,033
	n	128	128	128	128	128

Izvor: Izračun i prikaz autora

*Korelacija statistički značajna na razini značajnosti od 5 %,
** Korelacija statistički značajna na razini značajnosti od 1 %,
r - Pearsonov koeficijent korelacije, p - koeficijent značajnosti; (1) - default_proxy 2014, (2) - default_proxy 2015, (3) default_proxy 2016, (4) - default_proxy 2017, (5) - default_proxy 2018.

Nezavisne varijable *bsg_ubs*, *bzg_ubz* i *bng_ubn* nemaju statistički značajnu povezanost sa zavisnom varijablom te od nezavisnih varijablā prikazanih tablicom br. 63 jedino varijabla ocjena transparentnosti (*trans*) ima takva svojstva.

Temeljem prethodno opisanih rezultata korelacijske analize izdvojeno je sedam nezavisnih varijablā. Deskriptivni opis nezavisnih varijablā koje se koriste u daljnjem modeliranju nemogućnosti plaćanja dospjelih obveza nalazi se u tablici br. 68.

Tablica 68. Deskriptivna analiza sedam odabranih varijablā

Grupa	Varijabla (n = 640)	Minimum	Maksimum	Srednja vrijednost	Standardna devijacija	Raspon
FiP	*ppor_pp*	0,0840	0,8415	0,4810	0,1426	0,7575
	mpp_pp	0,0000	1,0425	0,0783	0,1278	1,0425
LiD	*okz_uo*	0,0000	1,0000	0,4015	0,3015	1,0000
	potp_pp	0,0032	1,5398	0,2766	0,2011	1,5366
	ki_ko	0,0000	358,3447	13,0321	19,8038	358,3447
	got_rp	0,0000	1,7158	0,1645	0,2011	1,7158
S	*trans*	0,0000	7,0000	3,2313	1,5624	7,0000

Izvor: Izračun i prikaz autora; FiP - Financije i proračun; LiD - Likvidnost i dug; S - Stanovništvo

Sukladno pregledu korelacija izdvojenih varijablā potrebno je napomenuti kako je u posljednjoj analiziranoj godini (2018.) zabilježena niža vrijednost koeficijenta korelacije te se navedeno može pripisati zakonskim promjena usred kojih su gradovima porasli proračunski prihodi. Tablica br. 69 sažeto prikazuje rezultate korelacijske analize za odabranih sedam nezavisnih varijablā.

Tablica 69. Korelacija sedam izdvojenih varijablā - Varijable izdvojene za izgradnju modela predviđanja nemogućnosti plaćanja dospjelih obveza gradova

Nezavisne varijable		**Zavisna varijabla - Omjer dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima**				
		(1)	(2)	(3)	(4)	(5)
Udio prihoda od poreza u prihodima poslovanja (*ppor_pp*)	r	-0,239**	-0,227**	-0,215*	-0,277**	-0,169
	p	0,007	0,010	0,015	0,002	0,057
	n	128	128	128	128	128
Omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*)	r	0,663**	0,757**	0,752**	0,743**	0,404**
	p	0,000	0,000	0,000	0,000	0,000
	n	128	128	128	128	128
Udio obveza za kredite i zajmove u ukupnim obvezama (*okz_uo*)	r	-0,172	-0,326**	-0,172	-0,252**	-0,257**
	p	0,052	0,000	0,052	0,004	0,003
	n	128	128	128	128	128
Omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*)	r	0,166	0,257**	0,323**	0,232**	0,145
	p	0,061	0,003	0,000	0,008	0,103
	n	128	128	128	128	128
Omjer kratkotrajne imovine i kratkoročnih obveza (*ki_ko*)	r	-0,232**	-0,199*	-0,275**	-0,386**	-0,142
	p	0,008	0,024	0,002	0,000	0,109
	n	128	128	128	128	128
Omjer gotovine i rashoda poslovanja (*got_rp*)	r	-0,062	-0,044	-0,198*	-0,205*	-0,098
	p	0,485	0,621	0,025	0,020	0,269
	n	128	128	128	128	128
Ocjena transparentnosti (*trans*)	r	-0,204*	-0,159	-0,171	-0,306**	-0,189*
	p	0,021	0,074	0,054	0,000	0,033
	n	128	128	128	128	128

Izvor: Izračun i prikaz autora

*Korelacija statistički značajna na razini značajnosti od 5 %,
** Korelacija statistički značajna na razini značajnosti od 1 %,
r - Personom koeficijent korelacije, p - koeficijent značajnosti; (1) - default_proxy 2014, (2) - default_proxy 2015, (3) - default_proxy 2016, (4) - default_proxy 2017, (5) - default_proxy 2018

Na temelju postojeće poslovne prakse utvrđen je očekivani smjer pojedine odabrane varijable na zavisnu varijablu (tablica br. 70). Očekivani je smjer potvrđen statističkom analizom kod pet nezavisnih varijablā.

Naime, povećanje omjera prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*) rezultira povećanjem omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima, odnosno porastom zavisne varijable (*default_proxy*). Istu pozitivnu korelaciju ima i porast potraživanja za prihode poslovanja (*potp_pp*). Negativna je korelacija kod omjera kratkotrajne imovine i kratkoročnih obveza (*ki_ko*) i gotovine i rashoda poslovanja (*got_rp*) koja povećava nemogućnost plaćanja obveza. Jednako tako, gradovi s nižom ocjenom transparentnosti (*trans*) u većoj mjeri ne plaćaju svoje obveze na vrijeme i u punom iznosu.

Za dva je pokazatelja utvrđen utjecaj drugačiji od onoga koji je bio očekivan. Naime, smanjen udio prihoda od poreza u prihodima poslovanja (*ppor_pp*) sugerira da je veći udio vlastitih prihoda, ali i prihoda od pomoći. Unatoč većoj fleksibilnosti koju donosi rast vlastitih prihoda, rast prihoda od pomoći povećava ovisnost o središnjoj vlasti i evidentno negativno utječe na zavisnu varijablu. Negativna je korelacija vezana i za udio obveza za kredite i zajmove u ukupnim obvezama (*okz_uo*) odnosno smanjenje zaduženosti gradova rezultira porastom dospjelih nepodmirenih obveza.

Tablica 70. Očekivani i stvarni smjer izdvojenih nezavisnih varijablā na zavisnu varijablu

Nezavisne varijable	Očekivani smjer	Stvarni smjer
Udio prihoda od poreza u prihodima poslovanja (*ppor_pp*)	Pozitivan	Negativan
Omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*)	Pozitivan	Pozitivan
Udio obveza za kredite i zajmove u ukupnim obvezama (*okz_uo*)	Pozitivan	Negativan
Omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*)	Pozitivan	Pozitivan
Omjer kratkotrajne imovine i kratkoročnih obveza (*ki_ko*)	Negativan	Negativan
Omjer gotovine i rashoda poslovanja (*got_rp*)	Negativan	Negativan
Ocjena transparentnosti (*trans*)	Negativan	Negativan

Izvor: Prikaz autora

7.1.4. Analiza varijance zavisnih podataka

Jednostavna analiza varijance zavisnih podataka provodi se za zavisnu varijablu te sedam nezavisnih varijablā i donosi pregled prosječnih vrijednosti gradova u Republici Hrvatskoj po godinama u analiziranom razdoblju od 2014. do 2018. godine. Niže prikazanim i opisanim trendovima, provedbom analize varijance zavisnih podataka, pridonosi većina gradova iz uzorka iako neki gradovi imaju manja ili veća odstupanja od opisnih trendova.

Analiza varijance zavisnih podataka provedena je kako bi se usporedili rezultati nemogućnosti plaćanja dospjelih obveza (*default_proxy*) od 2014. do 2018. godine. Aritmetička sredina i standardna devijacija te smjer kretanja aritmetičke sredine kroz vrijeme zapisani su u tablici br. 71 i grafikonu br. 6.

Tablica 71. Deskriptivan opis varijable *default_proxy*

Varijabla	Aritmetička sredina	Standardna devijacija	Standardna pogreška aritmetičke sredine	n
default_proxy_2014	0,103	0,1258	0,011	128
default_proxy_2015	0,091	0,1145	0,010	128
default_proxy_2016	0,076	0,1080	0,010	128
default_proxy_2017	0,083	0,1060	0,009	128
default_proxy_2018	0,054	0,0784	0,007	128

Izvor: Izračun i prikaz autora

Rezultati provedenog testa pokazuju statistički značajan učinak kroz vrijeme (Wilks'Lambda = 0,749, F(4, 124) = 10,368, p < 0,001 uz multivarijatni Partial Eta Squared 0,251). Rezultati Bonfferonijevog post-hoc testa ukazuju na postojanje statistički značajne razlike između pet promatranih vremenskih razdoblja. Statistički značajna razlika zabilježena je u rezultatima nemogućnosti plaćanja dospjelih obveza (*default_proxy*) u 2018. godini u odnosu na ostale analizirane godine. Utvrđena je i statistički značajna razlika između 2014. i 2016. godine. U ostalim usporedbama rezultata nisu pronađene statistički značajne razlike (detaljan zapis svih post-hoc testova poglavlja nalazi se u prilogu br. 5).

Grafikon 6. Usporedba aritmetičkih sredina zavisnih podataka - *default_proxy*

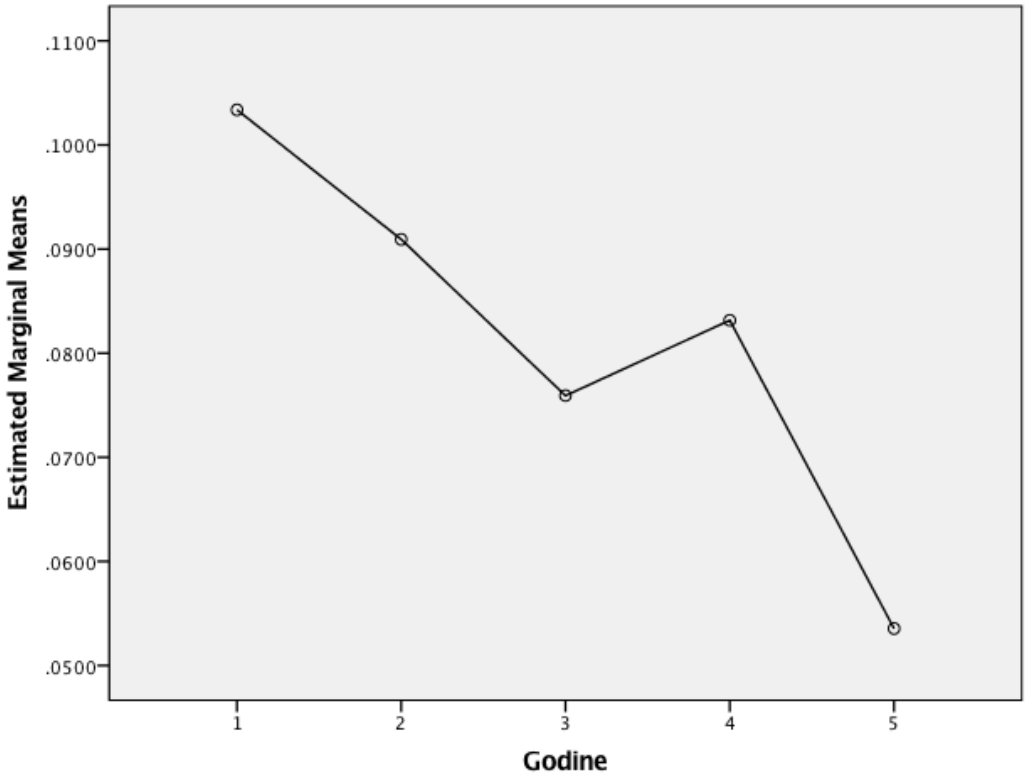

Izvor: Izračun i prikaz autora
1 – 2014. godina, 2 – 2015. godina, 3 – 2016. godina, 4 – 2017. godina, 5 – 2018. godina

Analiza varijance zavisnih podataka provedena je za nezavisne varijable te su tako uspoređeni rezultati za omjer prihoda od poreza i prihoda poslovanja (*ppor_pp*) za razdoblje od 2014. do 2018. godine. Aritmetička sredina i standardna devijacija te smjer kretanja aritmetičke sredine kroz vrijeme zapisani su u tablici br. 72 i grafikonu br. 7.

Tablica 72. Deskriptivan opis varijable *ppor_pp*

Varijabla	Aritmetička sredina	Standardna devijacija	Standardna pogreška aritmetičke sredine	n
ppor_pp_2014	0,502	0,1222	0,011	128
ppor_pp_2015	0,442	0,1396	0,012	128
ppor_pp_2016	0,457	0,1389	0,012	128
ppor_pp_2017	0,439	0,1418	0,013	128
ppor_pp_2018	0,565	0,1299	0,012	128

Izvor: Izračun i prikaz autora

Grafikon 7. Usporedba aritmetičkih sredina zavisnih podataka – *ppor_pp*

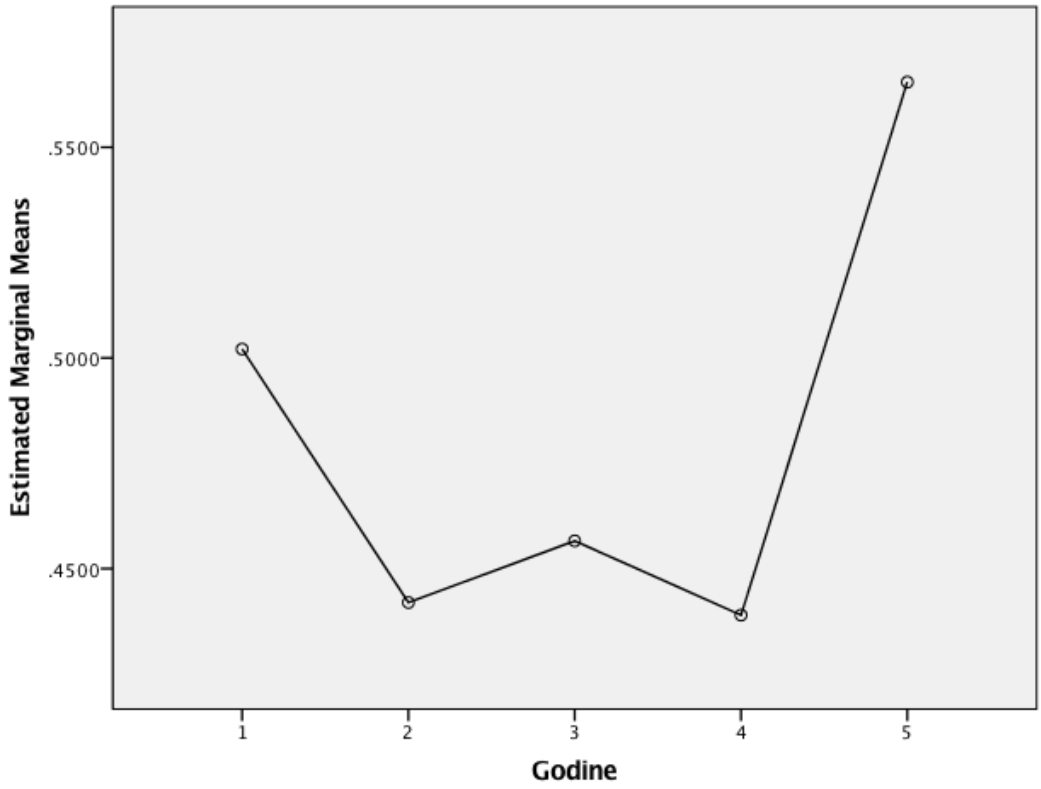

Izvor: Izračun i prikaz autora
1 – 2014. godina, 2 – 2015. godina, 3 – 2016. godina, 4 – 2017. godina, 5 – 2018. godina

Rezultati provedenog testa pokazuju statistički značajan učinak kroz vrijeme (Wilks'Lambda = 0,516, F(4, 124) = 29,072, p < 0,001 uz multivarijatni Partial Eta Squared 0,484). Rezultati Bonfferonijevog post-hoc testa ukazuju na postojanje statistički značajne razlike između pet promatranih vremenskih razdoblja. Statistički značajna razlika zabilježena je između svih promatranih razdoblja osim onih između 2015. godine u odnosu na 2016. i 2017. godinu.

Analiza varijance zavisnih podataka provedena je i u usporedbi rezultata za omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*) za razdoblje od 2014. godine do 2018. godine. Aritmetička sredina i standardna devijacija te smjer kretanja aritmetičke sredine kroz vrijeme zapisani su u tablici br. 73 i grafikonu br. 8.

Tablica 73. Deskriptivan opis varijable *mpp_pp*

Varijabla	Aritmetička sredina	Standardna devijacija	Standardna pogreška aritmetičke sredine	n
mpp_pp_2014	0,098	0,1411	0,012	128
mpp_pp_2015	0,091	0,1249	0,011	128
mpp_pp_2016	0,067	0,1091	0,010	128
mpp_pp_2017	0,078	0,1307	0,012	128
mpp_pp_2018	0,059	0,1287	0,011	128

Izvor: Izračun i prikaz autora

Grafikon 8. Usporedba aritmetičkih sredina zavisnih podataka – *mpp_pp*

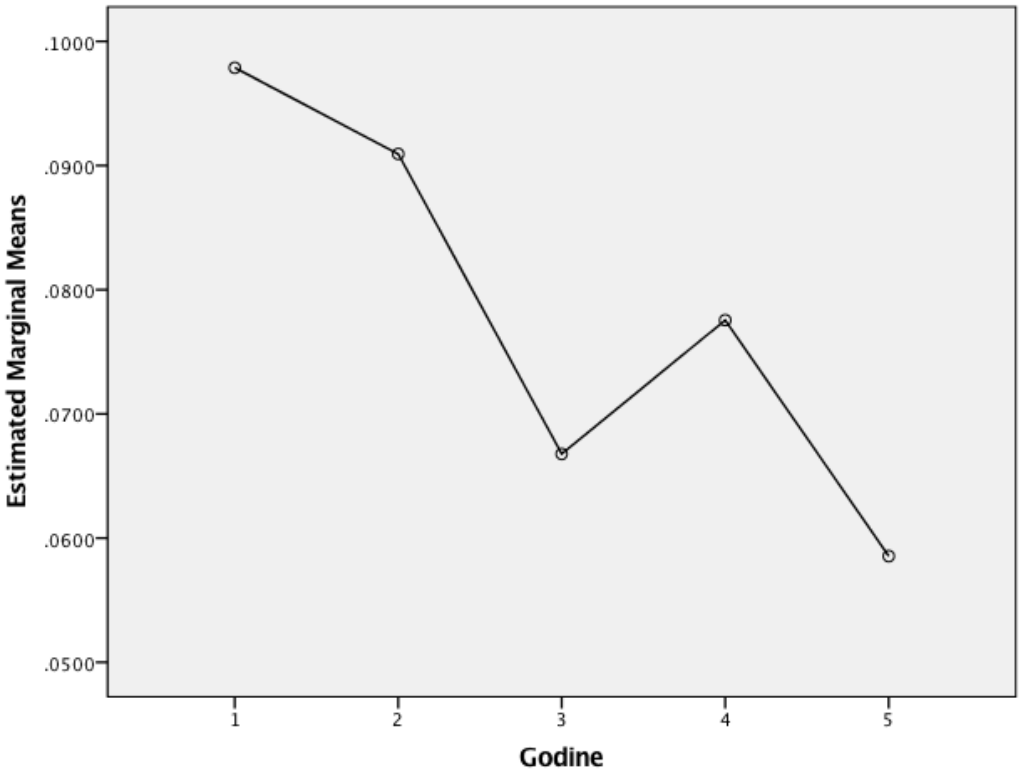

Izvor: Izračun i prikaz autora
1 – 2014. godina, 2 – 2015. godina, 3 – 2016. godina, 4 – 2017. godina, 5 – 2018. godina

Rezultati provedenog testa pokazuju statistički značajan učinak kroz vrijeme (Wilks'Lambda = 0,827, F(4, 124) = 6,5062, p < 0,001 uz multivarijatni Partial Eta Squared 0,173). Rezultati Bonfferonijevog post-hoc testa ukazuju na postojanje statistički značajne razlike između pet promatranih vremenskih razdoblja.

Statistički značajna razlika zabilježena je samo između 2016. godine u odnosu na 2014. i 2015. godinu. U ostalim usporedbama rezultata nisu pronađene statistički značajne razlike.

Uspoređeni su i rezultati za udio obveza za kredite i zajmove u ukupnim obvezama (*okz_uo*) za razdoblje od 2014. godine do 2018. godine. Aritmetička sredina i standardna devijacija te smjer kretanja aritmetičke sredine kroz vrijeme zapisani su u tablici br. 74 i grafikonu br. 9.

Tablica 74. Deskriptivan opis varijable *okz_uo*

Varijabla	Aritmetička sredina	Standardna devijacija	Standardna pogreška aritmetičke sredine	n
okz_uo_2014	0,418	0,2914	0,026	128
okz_ou_2015	0,432	0,3013	0,027	128
okz_uo_2016	0,410	0,3046	0,027	128
okz_uo_2017	0,396	0,3078	0,027	128
okz_uo_2018	0,351	0,3002	0,027	128

Izvor: Izračun i prikaz autora

Grafikon 9. Usporedba aritmetičkih sredina zavisnih podataka – *okz_uo*

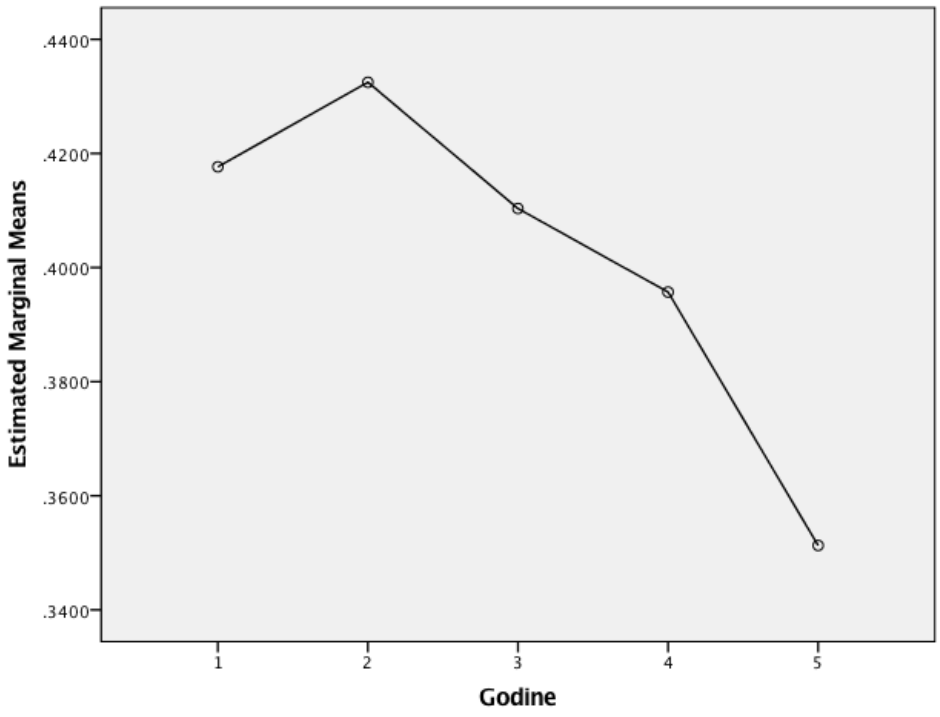

Izvor: Izračun i prikaz autora
1 – 2014. godina, 2 – 2015. godina, 3 – 2016. godina, 4 – 2017. godina, 5 – 2018. godina

Rezultati provedenog testa pokazuju statistički značajan učinak kroz vrijeme (Wilks'Lambda = 0,901, F(4, 124) = 3,394, p = 0,011 uz multivarijatni Partial Eta Squared 0,099). Rezultati Bonfferonijevog post-hoc testa ukazuju na postojanje statistički značajne razlike između pet promatranih vremenskih razdoblja. Statistički značajna razlika zabilježena je u 2018. godini u odnosu na sva ostala promatrana vremenska razdoblja. U ostalim usporedbama rezultata nisu pronađene statistički značajne razlike.

Uspoređeni su i rezultati varijablā omjer potraživanja za prihode poslovanje i prohoda poslovanja (*potp_pp*) za razdoblje od 2014. godine do 2018. godine. Aritmetička sredina i standardna devijacija te smjer kretanja aritmetičke sredine kroz vrijeme zapisani su u tablici br. 75 i grafikonu br. 10.

Tablica 75. Deskriptivan opis varijable *potp_pp*

Varijabla	Aritmetička sredina	Standardna devijacija	Standardna pogreška aritmetičke sredine	n
potp_pp_2014	0,292	0,1962	0,017	128
potp_pp_2015	0,316	0,2110	0,019	128
potp_pp_2016	0,291	0,1902	0,017	128
potp_pp_2017	0,289	0,2138	0,019	128
potp_pp_2018	0,196	0,1726	0,015	128

Izvor: Izračun i prikaz autora

Rezultati provedenog testa pokazuju statistički značajan učinak kroz vrijeme (Wilks'Lambda = 0,558, F(4, 124) = 24,506, p < 0,001 uz multivarijatni Partial Eta Squared 0,442). Rezultati Bonfferonijevog post-hoc testa ukazuju na postojanje statistički značajne razlike između pet promatranih vremenskih razdoblja.

Statistički značajna razlika zabilježena je u 2018. godini u odnosu na sva ostala promatrana vremenska razdoblja, isto tako i u 2015. godini u odnosu na ostala vremenska razdoblja. U ostalim usporedbama rezultata nisu pronađene statistički značajne razlike.

Grafikon 10. Usporedba aritmetičkih sredina zavisnih podataka – *potp_pp*

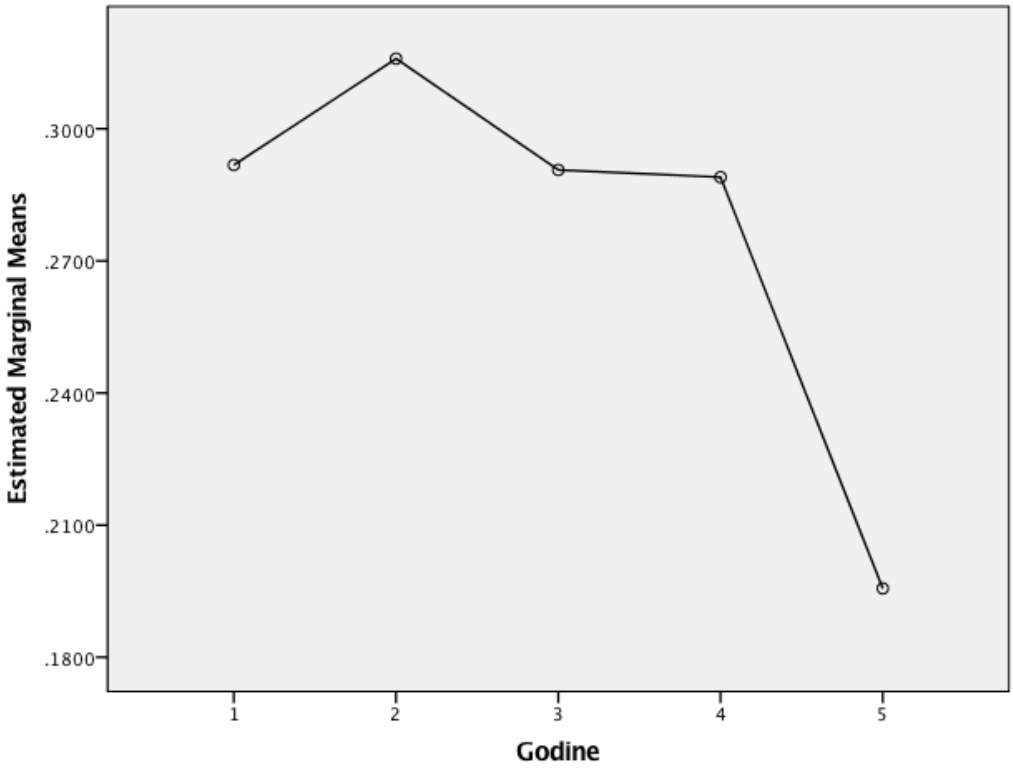

Izvor: Izračun i prikaz autora
1 – 2014. godina, 2 – 2015. godina, 3 – 2016. godina, 4 – 2017. godina, 5 – 2018. godina

Analizom varijanci zavisnih podataka uspoređeni su rezultati omjera kratkotrajne imovine i kratkoročnih obveza (*ki_ko*) za razdoblje od 2014. godine do 2018. godine. Aritmetička sredina i standardna devijacija te smjer kretanja aritmetičke sredine kroz vrijeme zapisani su u tablici br. 76 i grafikonu br. 11.

Tablica 76. Deskriptivan opis varijable *ki_ko*

Varijabla	Aritmetička sredina	Standardna devijacija	Standardna pogreška aritmetičke sredine	n
ki_ko_2014	13,429	19,7374	1,745	128
ki_ko_2015	15,364	32,7260	2,893	128
ki_ko_2016	13,643	15,8018	1,397	128
ki_ko_2017	12,622	12,4545	1,101	128
ki_ko_2018	10,103	9,6486	0,853	128

Izvor: Izračun i prikaz autora

Grafikon 11. Usporedba aritmetičkih sredina zavisnih podataka – *ki_ko*

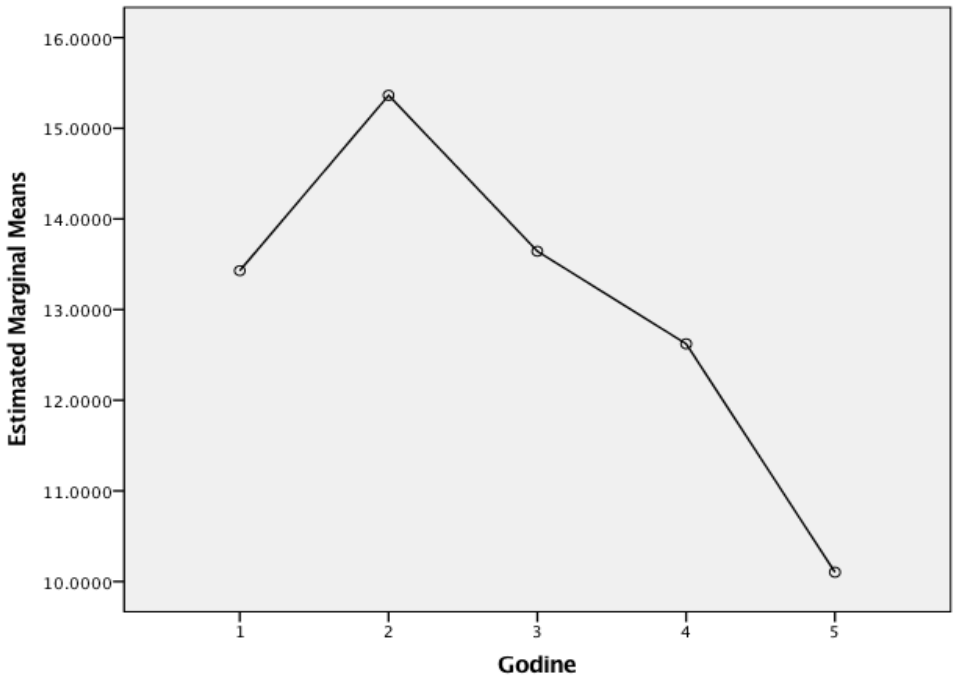

Izvor: Izračun i prikaz autora
1 – 2014. godina, 2 – 2015. godina, 3 – 2016. godina, 4 – 2017. godina, 5 – 2018. godina

Rezultati provedenog testa ne pokazuju statistički značajan učinak kroz vrijeme (Wilks'Lambda = 0,933, F(4, 124) = 2,210, p > 0,05). U usporedbama svih vremenskih razdoblja nisu pronađene statistički značajne razlike. Uspoređeni su i rezultati za omjer gotovine i rashoda poslovanja (*got_rp*) za razdoblje od 2014. godine do 2018. godine. Aritmetička sredina i standardna devijacija te smjer kretanja aritmetičke sredine kroz vrijeme zapisani su u tablici br. 77 i grafikonu br. 12.

Tablica 77. Deskriptivan opis varijable *got_rp*

Varijabla	Aritmetička sredina	Standardna devijacija	Standardna pogreška aritmetičke sredine	n
got_rp_2014	0,121	0,1378	0,012	128
got_rp_2015	0,119	0,1583	0,014	128
got_rp_2016	0,145	0,1598	0,014	128
got_rp_2017	0,179	0,2021	0,018	128
got_rp_2018	0,257	0,2826	0,025	128

Izvor: Izračun i prikaz autora

Grafikon 12. Usporedba aritmetičkih sredina zavisnih podataka – *got_rp*

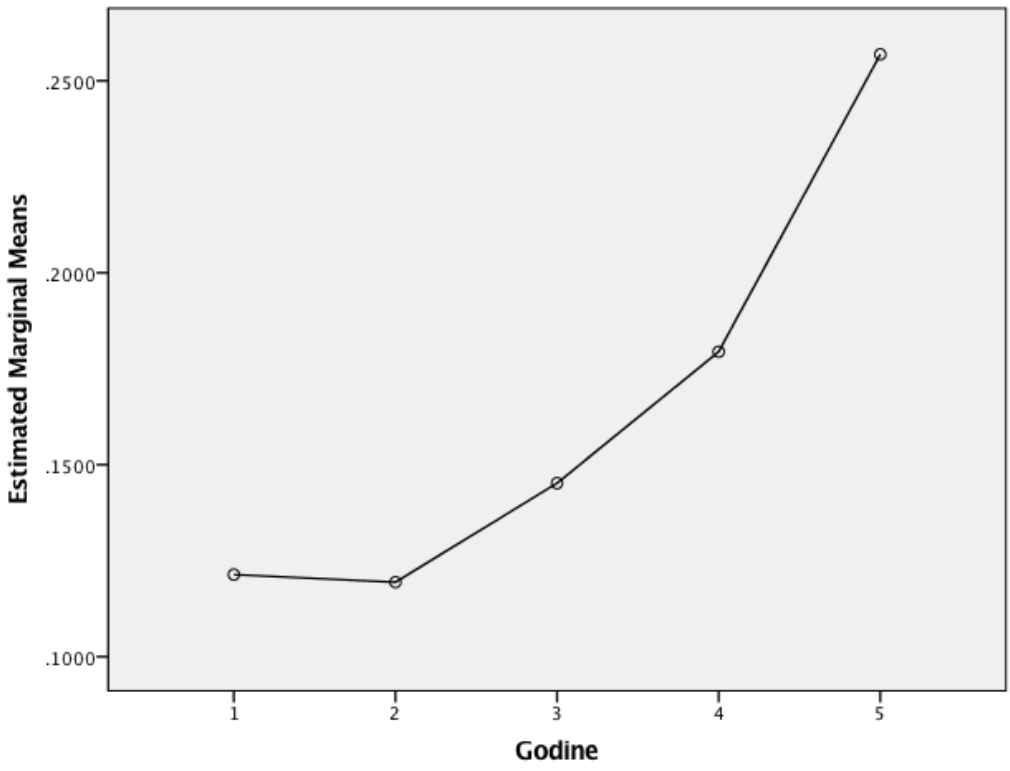

Izvor: Izračun i prikaz autora
1 – 2014. godina, 2 – 2015. godina, 3 – 2016. godina, 4 – 2017. godina, 5 – 2018. godina

Rezultati provedenog testa pokazuju statistički značajan učinak kroz vrijeme (Wilks'Lambda = 0,800, F(4, 124) = 7,728, p < 0,001 uz multivarijatni Partial Eta Squared 0,200). Rezultati Bonfferonijevog post-hoc testa ukazuju na postojanje statistički značajne razlike između pet promatranih vremenskih razdoblja. Statistički značajna razlika zabilježena je u 2018. godini u odnosu na sva ostala promatrana vremenska razdoblja. Također, pronađena je statistički značajna razlika između mjerenja u 2014. i 2017. godini, te između mjerenja u 2015. i 2017. godini. U ostalim usporedbama rezultata nisu pronađene statistički značajne razlike.

Analiza varijance zavisnih podataka provedena je i za usporedbu mjerenja ocjene transparentnosti (*trans*) za razdoblje od 2014. godine do 2018. godine. Aritmetička sredina i standardna devijacija te smjer kretanja aritmetičke sredine kroz vrijeme zapisani su u tablici br. 78 i grafikonu br. 13.

Tablica 78. Deskriptivan opis varijable *trans*

Varijabla	Aritmetička sredina	Standardna devijacija	Standardna pogreška aritmetičke sredine	n
Trans_2014	2,680	1,7521	0,155	128
Trans_2015	2,719	1,6068	0,142	128
Trans_2016	3,055	1,5487	0,137	128
Trans_2017	3,664	1,2998	0,115	128
Trans_2018	4,039	1,0454	0,092	128

Izvor: Izračun i prikaz autora

Grafikon 13. Usporedba aritmetičkih sredina zavisnih podataka - *trans*

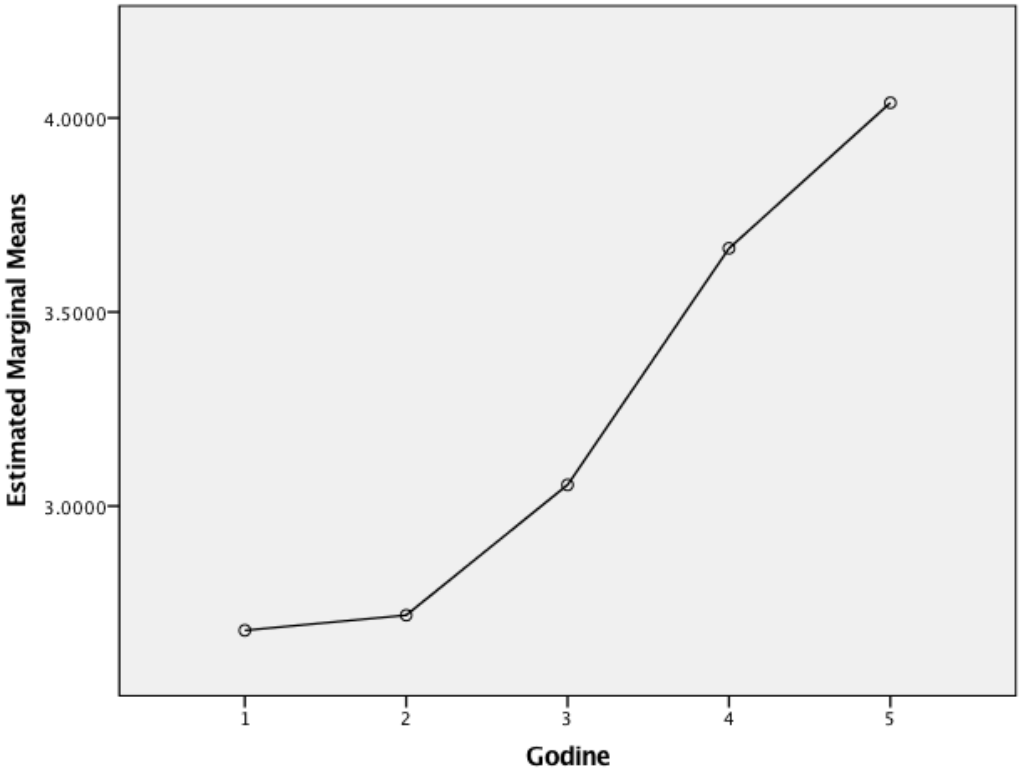

Izvor: Izračun i prikaz autora
1 – 2014. godina, 2 – 2015. godina, 3 – 2016. godina, 4 – 2017. godina, 5 – 2018. godina

Rezultati provedenog testa pokazuju statistički značajan učinak kroz vrijeme (Wilks'Lambda = 0,502, F(4, 124) = 30,728, p < 0,001 uz multivarijatni Partial Eta Squared 0,498). Rezultati Bonfferonijevog post-hoc testa ukazuju na postojanje statistički značajne razlike između pet promatranih vremenskih razdoblja. Statistički značajna razlika zabilježena je u mjerenjima između svih promatranih vremenskih razdoblja.

7.1.5. Ispitivanje odnosa među varijablama primjenom regresijske analize na panel-podatcima

Odnos nezavisnih varijablā i zavisne varijable nemogućnost plaćanja dospjelih obveza (*default_proxy*), moguće je u obuhvaćenom petogodišnjem razdoblju ispitati primjenom regresijske analize panel-podataka na način da se prate odnosi dviju varijabli kroz vrijeme. Temeljem postavljenih hipoteza, navedeni odnosi nezavisnih varijablā uparenih sa zavisnom varijablom grupirane su u tri postojeće skupine: *Financije i proračun*, *Likvidnost i dug* te *Stanovništvo*. Važno je napomenuti kako je na svim grafičkim prikazima zavisna varijabla koja predstavlja omjer dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default proxy*), iskazana kraticom *nepobv* uz oznaku godine za koju je izvršena analiza zbog ograničenja statističkog programa Mplus (broj znakova po varijabli), npr. *nepobv14* prikazuje nemogućnost plaćanja dospjelih obveza (*default_proxy*) u 2014. godini. U tablici br. 79 prikazane su skraćene oznake varijabli korištenih u analizi.

Tablica 79. Pregled oznaka analiziranih varijablā u programu Mplus

Opis varijable	**Varijabla**	**Mplus varijabla**
Omjer nepodmirenih obveza u ukupnim rashodima i izdatcima	*default_proxy*	nepobv
Udio prihoda od poreza u prihodima poslovanja	*ppor_pp*	ppor
Omjer prenesenog manjka prihoda i prihoda poslovanja	*mpp_pp*	mpp
Udio obveza za kredite i zajmove u ukupnim obvezama	*okz_uo*	okz
Omjer potraživanja za prihode poslovanja i prihoda poslovanja	*potp_pp*	potp
Omjer kratkotrajne imovine i kratkoročnih obveza	*ki_ko*	ki
Omjer gotovine i rashoda poslovanja	*got_rp*	got
Ocjena transparentnosti	*trans*	trans

Izvor: Prikaz autora

7.1.5.1. Financije i proračun

S obzirom na hipotezu *H1 - Karakteristike financija i proračuna gradova statistički su značajno povezane s neplaćanjem dospjelih obveza gradova*, ispitan je odnos izdvojenih nezavisnih varijablā[191] iz grupe *Financije i proračun* sa zavisnom varijablom. Analiza putanje modela koji ispituje odnos omjera prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*) i omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) prikazana je na slici br. 11.

[191] Varijable s jednakovrijednom razinom korelacije sa zavisnom varijablom

Slika 11. Prikaz rezultata putanje modela (*mpp_pp* i *default_proxy*)

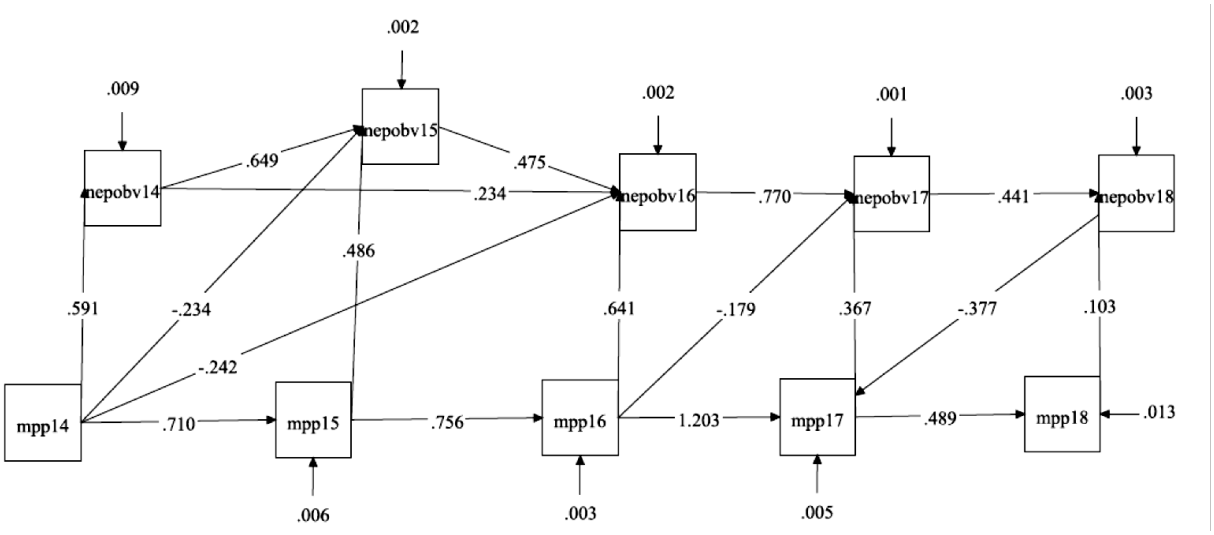

Izvor: Izračun i prikaz autora

Prikazani model odnosa omjera prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*) i omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) za razdoblje od 2014. do 2018. godina postiže dobre indekse pogodnosti (χ^2 = 48,203, df = 25, p < 0,01, CFI = 0,984, TLI = 0,972, RMSEA = 0,085, SRMR = 0,038). Na temelju prikazanih indeksa može se zaključiti da su navedene varijable umjereno, pozitivno povezane. To se osobito odnosi na razdoblje od 2014. do 2016. godine., dok su za 2017. i 2018. godinu ti koeficijenti nešto niži. Zanimljivo je istaknuti kako omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp*) predviđa kretanje omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*), ali u suprotnom smjeru. Drugim riječima, gradovi koji imaju visok omjer prenesenog manjka prihoda u prihodima poslovanja, u istoj godini imaju i visoku razinu omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*), ali već u sljedećoj godini to rezultira nižim vrijednostima zavisne varijable (*default_proxy*).

Druga analiza putanje modela iz grupe *Financije i proračun* ispituje odnos udjela prihoda od poreza u prihodima poslovanja (*ppor_pp*) i omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima za razdoblje (*default_proxy*) i prikazana je slikom br. 12.

Slika 12. Prikaz rezultata putanje modela (*ppor_pp* i *default_proxy*)

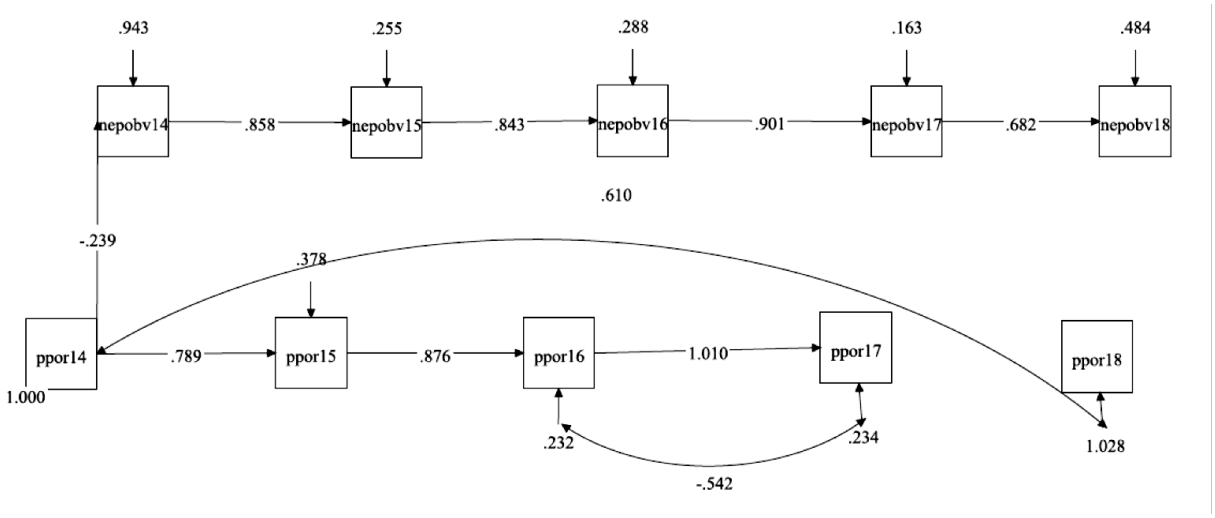

Izvor: Izračun i prikaz autora

Testiranjem modela s prikazanom nezavisnom varijablom (*ppor_pp*), model nije postigao adekvatne indekse pogodnosti (χ^2 = 106,75, df = 28, p < 0,01 CFI = 0,938, TLI = 0,900; RMSEA = 0,148, SRMR = 0,069) te stoga nije moguća interpretacija odnosa između varijabli u modelu.

7.1.5.2. Likvidnost i dug

Unutar grupe *Likvidnost i dug*, a temeljem hipoteze *H2 – Karakteristike likvidnosti i duga gradova statistički su značajno povezane s neplaćanjem dospjelih obveza gradova*, ispitan je odnos četiri izdvojene nezavisne varijable sa zavisnom varijablom nemogućnost plaćanja dospjelih obveza (*default_proxy*). Analiza putanje modela koji ispituje odnos udjela obveza za kredite i zajmove u ukupnim obvezama (*okz_uo*) i omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) prikazana je na slici br. 13.

Prikazani odnos izdvojene nezavisne varijable udio obveza za kredite i zajmove u ukupnim obvezama (*okz_uo*) i zavisne varijable nemogućnost plaćanja dospjelih obveza (*default_proxy*) postiže zadovoljavajuće indekse pogodnosti (χ^2 = 49,131, df = 28, p < 0,01, CFI = 0,984, TLI = 0,975, RMSEA = 0,077, SRMR = 0,063) te ukazuje na njihovu nisku, negativnu povezanost. Ova je povezanost statistički značajna za 2014., 2015. i 2017. godinu. Važno je napomenuti da je 2017. godina specifična jer je nezavisna varijabla (*okz_uo*), negativno povezana sa zavisnom varijablom (*default_proxy*) u 2018. godini, što je jedini takav slučaj.

Slika 13. Prikaz rezultata putanje modela (*okz_uo* i *default_proxy*)

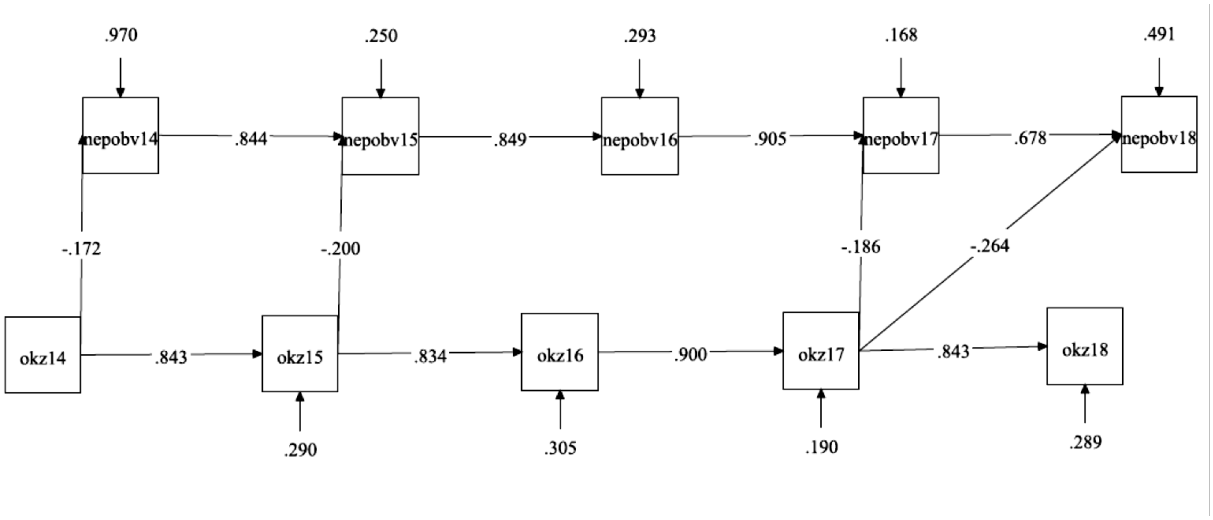

Izvor: Izračun i prikaz autora

Neosporna je činjenica kako je u 2017. godini veći porast udjela duga za kredite i zajmove u ukupnim obvezama, rezultirao smanjenjem dospjelih neplaćenih obveza godinu kasnije. Druga analiza putanje modela koji ispituje odnos omjera potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*) i omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) prikazana je na slici br. 14.

Slika 14. Prikaz rezultata putanje modela (*potp_pp* i *default_proxy*)

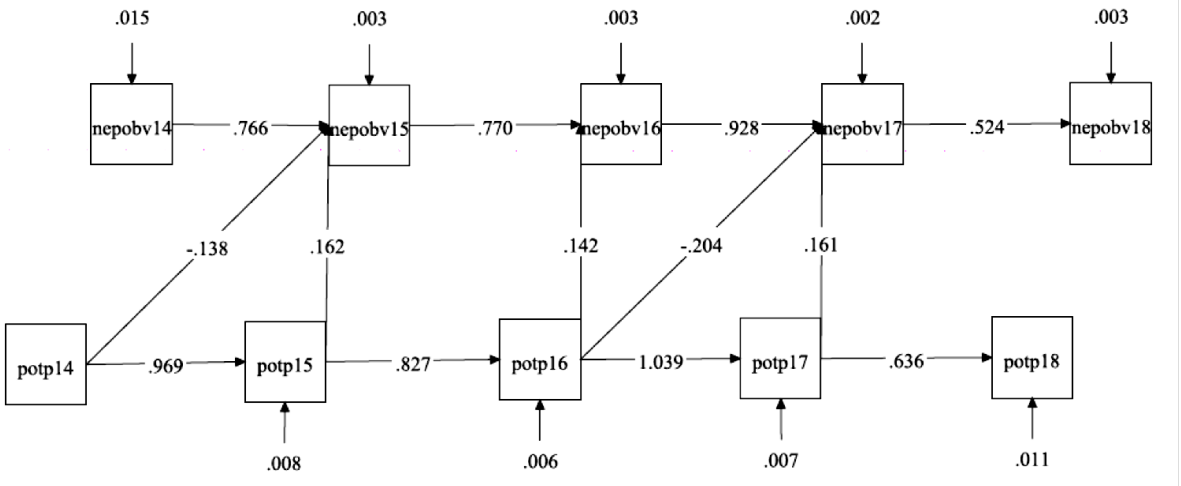

Izvor: Izračun i prikaz autora

Prikazani model, s dobrim indeksima pogodnosti (χ^2 = 51,942, df = 28, p < 0,01, CFI = 0,984, TLI = 0,975, RMSEA = 0,082, SRMR = 0,050) ukazuje na nisku i pozitivnu povezanost između omjera potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*) i omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) za razdoblje od 2014.

do 2018. godine. Povezanost se pokazala statistički značajnom za godine 2015., 2016. i 2017. Osim ovih povezanosti, opažene su i negativne povezanosti nezavisne varijable (*potp_pp*) za 2014. godinu i zavisne varijable (*default_proxy*) za 2015. godinu te nezavisne varijable (*potp_pp*) za 2016. godinu i zavisne varijable (*default_proxy*) za 2017. godinu.

Konačno, uočen je i tzv. Heywoodov slučaj u odnosu na putanju između nezavisne varijable (*potp_pp*) za 2016. godinu i nezavisne varijable (*potp_pp*) za 2017. godinu, što predstavlja još jednu iznimku 2017. godine. Naime, koeficijent veći od teorijski dopuštenog rezultat je visoke povezanost navedenih nezavisnih varijablā u 2016. i 2017. godini koji je u kompleksnim odnosima s drugim varijablama u modelu objasnio više od 100 % varijance. Ovakav je slučaj relativno čest u longitudinalnim istraživanjima poput ovog te se može valjano interpretirati kao maksimalna povezanost između varijabli. Drugim riječima, nezavisna varijabla (*potp_pp*) izrazito je stabilna u vremenu, te će gradovi koji imaju visok omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*) u prethodnoj godini, imati visok omjer i u godini koja slijedi. To ne znači da se na razini cijelog uzorka ne mijenja aritmetička sredina, već se samo zadržava isti odnos među promatranim gradovima.

Treća analiza putanje modela, iz grupe *Likvidnost i dug*, koji ispituje odnos omjera kratkotrajne imovine i kratkoročnih obveza (*ki_ko*) i omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) prikazana je na slici br. 15.

Slika 15. Prikaz rezultata putanje modela (*ki_ko* i *default_proxy*)

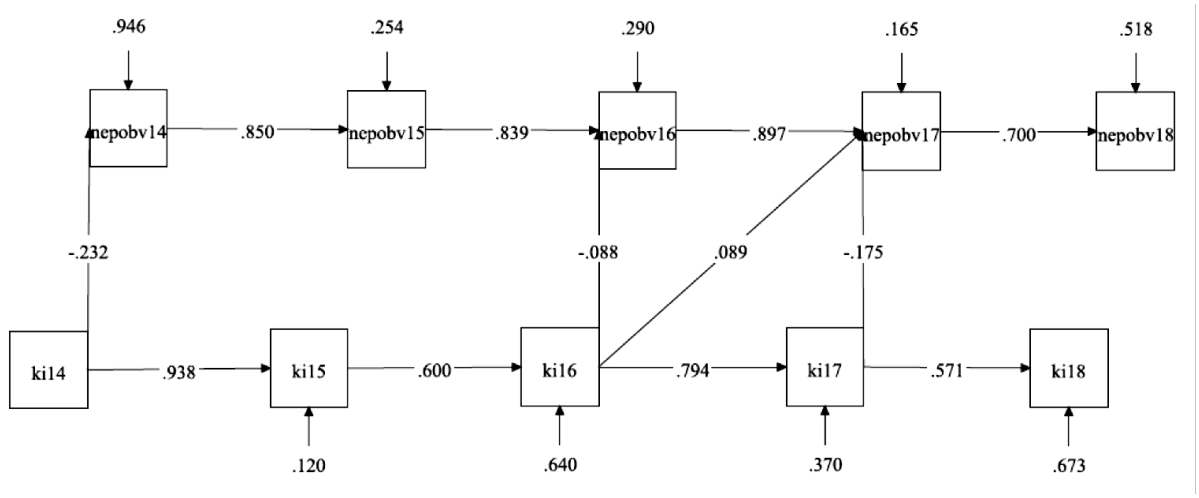

Izvor: Izračun i prikaz autora

Model koji je ispitivao odnos omjera kratkotrajne imovine i kratkoročnih obveza (*ki_ko*) i omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) prikazan na gornjoj slici, postigao je dobre indekse pogodnosti (χ^2 = 45,958, df = 28, p < 0,05 CFI = 0,985, TLI = 0,975, RMSEA = 0,070, SRMR = 0,067). Prema modelu, nezavisna varijabla *ki_ko* negativno je povezana sa zavisnom varijablom (*default_proxy*) u 2014., 2016., te 2017. godini. Povezanosti su relativno niske i nestabilne tijekom vremena (budući da ne postoje za 2015. i 2018. godinu). Generalno, kada se uzmu svi podatci u obzir, moglo bi se reći da postoji blaga i negativna povezanost nezavisne varijable (*ki_ko*) i nemogućnosti plaćanja dospjelih obveza (*default_proxy*), no da ona ne vrijedi za svaku godinu. Kao i u nekim prethodnim slučajevima, 2017. godina je iznimna, budući da je nezavisna varijabla (*ki_ko*) iz 2016. godine pozitivni prediktor zavisne varijable (*default_proxy*) za 2017. godinu.

Posljednja analiza putanje modela, iz grupe *Likvidnost i dug*, koji ispituje odnos omjera gotovine i rashoda poslovanja (*got_rp*) i omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) prikazana je na slici br. 16.

Slika 16. Prikaz rezultata putanje modela (*got_rp* i *default_proxy*)

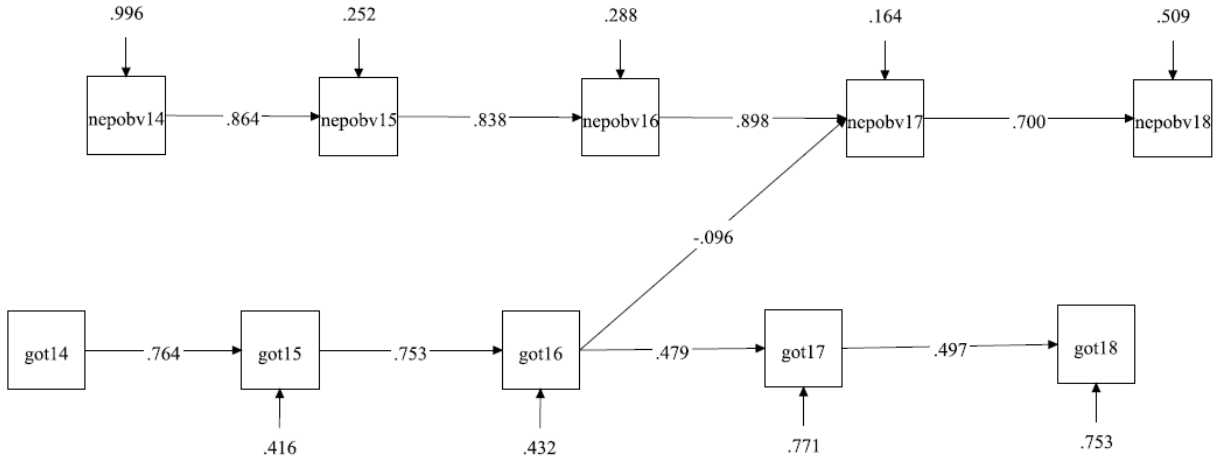

Izvor: Izračun i prikaz autora

Omjer gotovine i rashoda poslovanja (*got_rp*) nije povezan s omjerom dospjelih i nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*). Jedina iznimka je odnos nezavisne varijable *got_rp* za 2016. godinu i zavisne varijable (*default_proxy*) za 2017. godinu. Međutim, povezanost je manja od r = 0,10, što će reći da je u pitanju vrlo slaba, gotova zanemariva povezanost.

Ostali odnosi među varijablama nisu prikazani jer nisu statistički značajni na razini od $p < 0,05$. S druge strane, vidljivo je da je nezavisna varijabla *got_rp* prilično stabilna u razdoblju od 2014. do 2016. godine. Financijska godina 2017. čini se po svemu sudeći atipična godina, što se očituje u nižoj povezanost nezavisne varijable *got_rp* u razdoblju od 2016. do 2018. godine. Model u cjelini ima zadovoljavajuće indekse pogodnosti ($\chi^2 = 42,626$, df = 28, $p < 0,05$, CFI = 0,985, TLI = 0,975, RMSEA = 0,064, SRMR = 0,063).

7.1.5.3. Stanovništvo

U skupini *Stanovništvo*, jedna je izdvojena nezavisna varijabla za koju je ispitan odnos sa zavisnom varijablom vezan za hipotezu *H3 – Ekonomske karakteristike gradova statistički su značajno povezane s neplaćanjem dospjelih obveza gradova*. Naime, analiza putanje modela koji ispituje odnos ocjene transparentnosti (*trans*) i omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*), prikazana je na slici br. 17.

Slika 17. Prikaz rezultata putanje modela (*trans* i *default_proxy*)

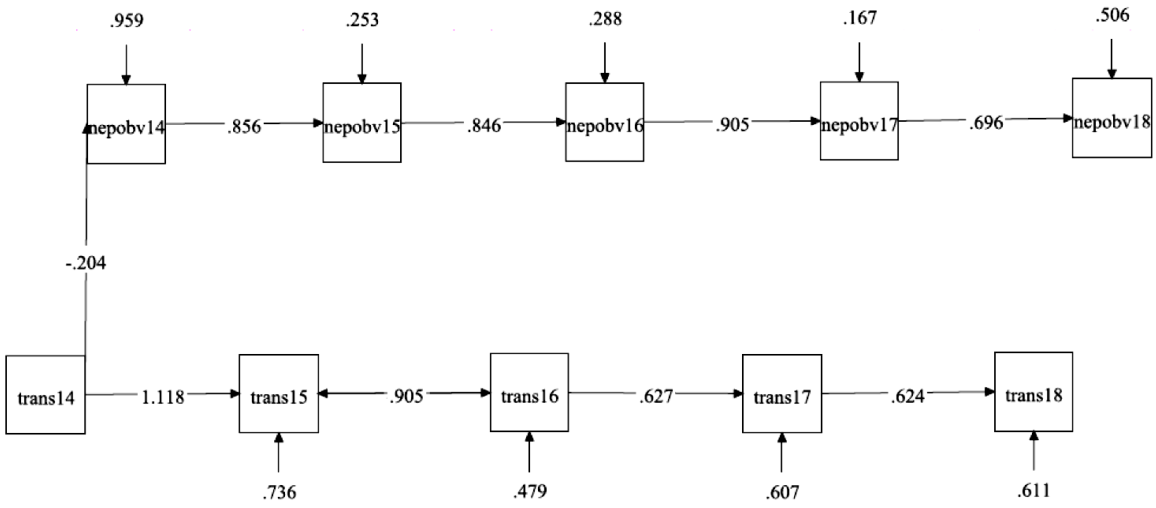

Izvor: Izračun i prikaz autora

Gornji model ($\chi^2 = 28,967$, df = 26, $p > 0,05$, CFI = 0,995, TLI = 0,991, RMSEA = 0,030, SRMR = 0,082) prikazuje nisku, negativnu povezanost između ocjene transparentnosti (*trans*) i omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) samo za 2014. godinu. Za ostale godine takav odnos nije statistički značajan. Također, primjetan je Heywoodov slučaj kod odnosa nezavisne varijable (*trans*) iz 2014. godine s 2015. godinom.

Kod transparentnosti su vidljive veće temporalne nestabilnosti u smislu da se koeficijent povezanosti iz godine u godinu mijenjao. Naročito je osjetan pad povezanosti za razdoblje od 2016. do 2018. godine.

7.1.6. Oblikovanje modela za izračun nemogućnosti plaćanja obveza gradova (analiza latentne krivulje rasta)

Kako bi dodatno ispitali dinamiku kretanja omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*), korištena je analiza latentnog rasta krivulje. Prema slici br. 18 može se uočiti način na koji je modelirano vrijeme i način na koji su kreirani faktorski bodovi početne vrijednosti, te dinamike kretanja. Svi parametri koji su korišteni za izračun početne vrijednosti omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) fiksirani su vrijednostima 1, dok su za dinamiku kretanja fiksirani vrijednostima 0, 1, 2 i 4.

Slika 18. Prikaz modela testiranog latentnom analizom rasta krivulje

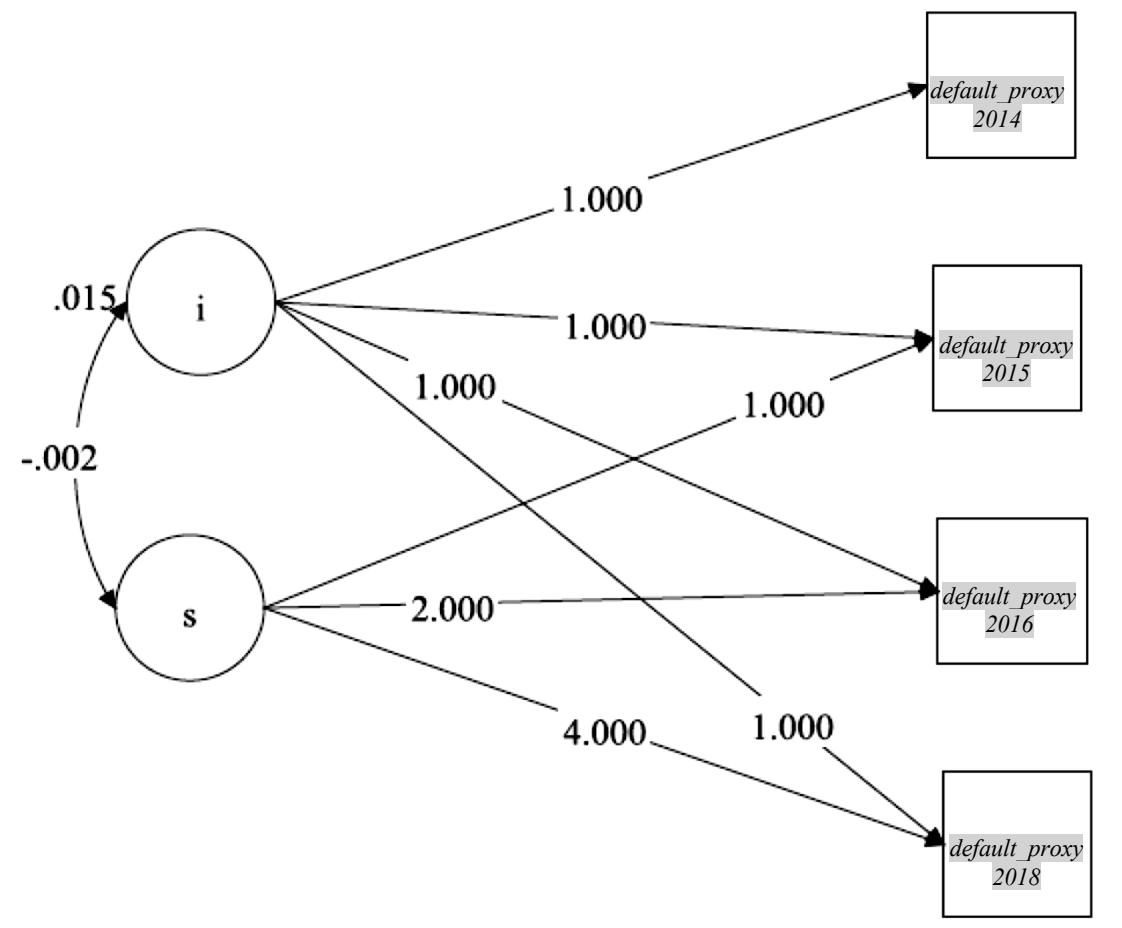

Izvor: Izračun i prikaz autora
Početna vrijednost (engl. *intercept* - *i*), dinamika kretanja (engl. *slope* – *s*)

Jedina varijabla koja nije uzeta u obzir u izračunu nove modelske varijable je *default_proxy_2017*. Spomenuta varijabla pokazala je značajna odstupanja od linearnog trenda pravca kretanja vrijednosti omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima po godinama. Krivulja trenda kreirana temeljem svih *default_proxy* varijablā nije pravilnog oblika koji bi omogućavao korištenje odgovarajuće matematičke formulacije za ispitivanje dobro poznatih nelinearnih funkcija kao što su logaritamska, eksponencijalna, inverzna, i slične funkcije. Iako postoji mogućnost za korištenje svih podataka primjenom, tzv. *piecewise* metode[192] kojom se model prilagođava prikupljenim podatcima, provedba spomenute metode nije rezultirala prikladnim indeksima pogodnosti. Stoga se u nastavka rada prikazuje model kreiran bez 2017. godine (*default_proxy_2017*). Za procjenu parametara gore prikazanog modela, korištena je robusna *maximum likelihood* metoda čiji je faktor korekcije iznosio 1,5911. Indeksi pogodnosti su bili zadovoljavajući (χ^2 = 6,583, df = 5, p > 0,05, CFI = 0,980, TLI = 0,977, RMSEA = 0,050, SRMR = 0,053), što je omogućilo kreiranje novih varijabli, inicijalne vrijednosti i stope rasta. Deskriptivni podatci nestandardiziranih rezultata početne vrijednosti su M (intercept) = 0,103, Sem (standardna pogreška aritmetičke sredine intercepta) = 0,011, M/Sem = 9,138, p < 0,001. Nestandardizirana dinamika kretnja iznosi M (slope) = -0,013, Sem = 0,002, M/Sem = -5,380, p < .001. Obje varijable statistički značajno variraju, što omogućava daljnju analizu povezanosti prediktora s novokreiranim varijablama koje ukazuju na dinamiku kretanja omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) tijekom razdoblja 2014. do 2018. godina.

Drugim riječima, gradovi su se značajno razlikovali s obzirom na omjer dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) u 2014. godini, tj. kretali su sa različitih pozicija na startu promatranog razdoblja. Prosječni pad dospjelih neplaćenih obveza iznosio je -0,013, što odgovara smanjenju nemogućnosti plaćanja dospjelih obveza od 1,3 % za promatrani uzorak. Međutim, taj pad nije bio jednak za sve gradove, već su postojali neki gradovima koji su imali veći pad, te manji broj onih koji su imali i rast omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*). Korelacija početne vrijednosti i dinamike kretanja je visoka i negativna (r = -0,842, p < 0,001), što se interpretira na način da oni gradovi koji su imali višu vrijednost omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) u 2014. godini, imali su nižu stopu pada nepodmirenih obveza (zbog negativne aritmetičke sredine varijable *slope*) u odnosu na

[192] *Piecewise* metoda sastoji se od dekomponiranja krivulje na dva ili više dijelova krivulje koji zadovoljavaju uvjet linearnosti, tj. manjih krivulja koje se mogu promatrati kao dva odvojena modela.

one koji su u 2014. imali nižu početnu vrijednost zavisne varijable (*default_proxy*), tj. gradova koji su 2014 imali manje nepodmirenih obveza. Drugim riječima, gradovi s manjim dugovima u 2014. godine brže su smanjivali dugovanja u promatranom razdoblju (do 2018.), i *vice versa*. Ovako visoka i negativna korelacija početne vrijednosti i dinamike kretanja može biti rezultat kratkog promatranog razdoblja odnosno činjenice da u većini promatranog razdoblja nije dolazilo do promjene vlasti i nije bilo značajne promjene u upravljanju gradovima. Gradovi s većim početnim neplaćenim dugom, manje su taj dug smanjivali od preostalih gradova. Za pretpostaviti je da bi dulje vremenske serije snizile razinu korelacije. Podlogu provedenih analiza latentnog rasta krivulje čine individualne krivulje rasta izrađene za svaki grad u Republici Hrvatskoj odnosno svaki grad ima svoju početnu vrijednost u 2014. godini te dinamiku kretanja u razdoblju od 2015. do 2018. godine (tablica br. 80).

Početna vrijednost grupirana je u tri kategorije: niska, srednja i visoka razina dospjelih, neplaćenih obveza na početku promatranog razdoblja. Niska razina (obojana zeleno) kretala se u rasponu od -0,11 do -0,09 te su se 34 grada nalazila u ovoj kategoriji. Radi se o gradovima koji su bili bez dospjelih, neplaćenih obveza (npr. Dubrovnik, Krapina, Ozalj i sl.) te gradovima koji su imali vrijednost zavisne varijable (*default_proxy*) na minimalnim razinama. Srednju razinu (obojanu žuto) čine gradovi čija se početna vrijednost kretala u rasponu od -0,089 do 0,00. Takvih je gradova bilo 51. U posljednjoj su kategoriji gradovi (njih 43) čija je početna vrijednost bila pozitivna i kretala se sve do 0,5. U toj su kategoriji, na samom začelju, gradovi koji su imali najlošiju *startnu* poziciju na početku istraživanjem obuhvaćenog razdoblja s vrijednostima zavisne varijable (*default_proxy*) većima od 40 % (npr. Orahovica, Otočac i Trogir). Dinamika kretanja dospjelih neplaćenih obveza svih gradova te pripadajuća brzina promjene u nastavku promatranog razdoblja (2015. godina do 2018. godina) također su prikazani u tablici br. 83. Brzina, koja se kretala u rasponu od -0,093 do 0,0373, govori o nagibu krivulje te veći nagib može označava i brže smanjenje ili pak brži rast dospjelih, neplaćenih obveza i obrnuto. Radi lakšeg tumačenja brzina promjene isto je podijeljena u tri kategorije: niska, srednja i visoka. Nisku brzinu imaju gradovi (njih 20) kod kojih nije bilo značajnih oscilacija u iznosu zavisne varijable (*default_proxy*) te čija se brzina kretala u rasponu od 0,012 do 0,013. Ponajprije je tu riječ o gradovima koji tijekom cijelog promatranog razdoblja nisu imali dospjelih, neplaćenih obveza. U srednjoj su kategoriji gradovi čija se brzina kretala u rasponu od -0,0149 do 0,0119 te u rasponu od 0,0131 do 0,0149. Takvih je gradova bilo 78. Visoku brzinu ostvarilo je 30 gradova (raspon čine brzine veće od +/- 0,0149) te je većina njih imala visoku razinu dospjelih, neplaćenih obveza na početku petogodišnjeg razdoblja.

Tablica 80. Prikaz početne vrijednosti i dinamike kretanja zavisne varijable za sve gradove (uređenje prema silaznoj vrijednosti brzine promjene i uzlaznoj vrijednosti početne vrijednosti)

Naziv grada	Početna vrijednost (Intercept)	Razina dospjelih, neplaćenih obveza na početku promatranog razdoblja	Dinamika kretanja (Slope)	Brzina promjene od 2015. do 2018.	Oznaka smjera
DUBROVNIK	-0,1002	Niska	0,0129	Niska	→
KRAPINA	-0,1002	Niska	0,0129	Niska	→
OZALJ	-0,1002	Niska	0,0129	Niska	→
ROVINJ	-0,1002	Niska	0,0129	Niska	→
SLUNJ	-0,1002	Niska	0,0129	Niska	→
VRBOVSKO	-0,1002	Niska	0,0129	Niska	→
ZABOK	-0,1002	Niska	0,0129	Niska	→
SVETI IVAN ZELINA	-0,1002	Niska	0,0129	Niska	↓
IVANEC	-0,0999	Niska	0,0128	Niska	→
CRIKVENICA	-0,0993	Niska	0,0130	Niska	→
OGULIN	-0,0991	Niska	0,0130	Niska	→
KARLOVAC	-0,0982	Niska	0,0127	Niska	→
VIROVITICA	-0,0982	Niska	0,0130	Niska	→
SVETA NEDJELJA	-0,0977	Niska	0,0125	Niska	→
JASTREBARSKO	-0,0970	Niska	0,0123	Niska	↑
POREČ	-0,0965	Niska	0,0122	Niska	↑
LABIN	-0,0963	Niska	0,0128	Niska	↓
VARAŽDINSKE TOPLICE	-0,0940	Niska	0,0120	Niska	↓
BUZET	-0,0922	Niska	0,0124	Niska	↑
PULA	-0,0864	Srednja	0,0120	Niska	↑
NOVIGRAD	-0,0977	Niska	0,0145	Srednja	↓
NOVSKA	-0,0973	Niska	0,0137	Srednja	↓
ZAGREB	-0,0968	Niska	0,0145	Srednja	↓
VELIKA GORICA	-0,0933	Niska	0,0117	Srednja	→
VRBOVEC	-0,0933	Niska	0,0115	Srednja	→
OSIJEK	-0,0930	Niska	0,0117	Srednja	↑
BUJE	-0,0926	Niska	0,0119	Srednja	↑
POPOVAČA	-0,0921	Niska	0,0143	Srednja	↓
NAŠICE	-0,0919	Niska	0,0119	Srednja	↑
UMAG	-0,0910	Niska	0,0118	Srednja	↑
KASTAV	-0,0909	Niska	0,0112	Srednja	↑
ĐURĐEVAC	-0,0909	Niska	0,0113	Srednja	↑
GLINA	-0,0872	Srednja	0,0099	Srednja	↑
NOVA GRADIŠKA	-0,0845	Srednja	0,0097	Srednja	↑
SISAK	-0,0840	Srednja	0,0117	Srednja	↓
HVAR	-0,0833	Srednja	0,0111	Srednja	↓

POŽEGA	-0,0832	Srednja	0,0099	Srednja	↑
SAMOBOR	-0,0811	Srednja	0,0104	Srednja	→
BELI MANASTIR	-0,0795	Srednja	0,0148	Srednja	↑
DUGA RESA	-0,0777	Srednja	0,0082	Srednja	↑
ZAPREŠIĆ	-0,0763	Srednja	0,0076	Srednja	↑
DUGO SELO	-0,0745	Srednja	0,0096	Srednja	↑
NOVALJA	-0,0735	Srednja	0,0098	Srednja	↑
BJELOVAR	-0,0730	Srednja	0,0068	Srednja	↑
KUTINA	-0,0711	Srednja	0,0143	Srednja	↓
NIN	-0,0686	Srednja	0,0077	Srednja	↑
SPLIT	-0,0656	Srednja	0,0096	Srednja	↑
LEPOGLAVA	-0,0628	Srednja	0,0092	Srednja	↓
DONJA STUBICA	-0,0607	Srednja	0,0067	Srednja	↑
TRILJ	-0,0594	Srednja	0,0071	Srednja	↓
OROSLAVJE	-0,0591	Srednja	0,0115	Srednja	↑
SINJ	-0,0566	Srednja	0,0046	Srednja	↑
VUKOVAR	-0,0558	Srednja	0,0038	Srednja	↑
IVANIĆ-GRAD	-0,0551	Srednja	0,0045	Srednja	↑
BELIŠĆE	-0,0509	Srednja	0,0070	Srednja	↑
KRALJEVICA	-0,0492	Srednja	0,0019	Srednja	↑
PREGRADA	-0,0472	Srednja	0,0044	Srednja	↑
MURSKO SREDIŠĆE	-0,0470	Srednja	0,0048	Srednja	↑
SKRADIN	-0,0457	Srednja	0,0068	Srednja	↓
ŽUPANJA	-0,0446	Srednja	0,0042	Srednja	↑
KAŠTELA	-0,0423	Srednja	0,0014	Srednja	↑
SLATINA	-0,0416	Srednja	0,0027	Srednja	↑
MAKARSKA	-0,0410	Srednja	0,0074	Srednja	↑
KOPRIVNICA	-0,0372	Srednja	0,0064	Srednja	↓
STARI GRAD	-0,0298	Srednja	0,0004	Srednja	↑
SENJ	-0,0263	Srednja	0,0054	Srednja	↑
VODICE	-0,0243	Srednja	0,0100	Srednja	↑
ČAKOVEC	-0,0211	Srednja	0,0108	Srednja	↓
KLANJEC	-0,0142	Srednja	-0,0007	Srednja	↑
SLAVONSKI BROD	-0,0141	Srednja	-0,0036	Srednja	↑
SOLIN	-0,0130	Srednja	-0,0021	Srednja	↑
PAZIN	-0,0113	Srednja	0,0052	Srednja	↓
OPUZEN	-0,0109	Srednja	0,0021	Srednja	↓
GRUBIŠNO POLJE	-0,0058	Srednja	0,0041	Srednja	↑
ĐAKOVO	-0,0050	Srednja	-0,0065	Srednja	↑
DRNIŠ	-0,0048	Srednja	0,0015	Srednja	↓
ČAZMA	-0,0025	Srednja	0,0080	Srednja	↓
NOVI MAROF	0,0033	Visoka	-0,0046	Srednja	↑
KORČULA	0,0037	Visoka	-0,0025	Srednja	↓
PAKRAC	0,0037	Visoka	-0,0070	Srednja	↑
VIS	0,0043	Visoka	0,0031	Srednja	↓
DARUVAR	0,0063	Visoka	-0,0074	Srednja	↑
PAG	0,0142	Visoka	-0,0038	Srednja	↑
LUDBREG	0,0154	Visoka	-0,0060	Srednja	↑

KOMIŽA	0,0175	Visoka	-0,0076	Srednja	
KRIŽEVCI	0,0209	Visoka	-0,0105	Srednja	
IMOTSKI	0,0325	Visoka	-0,0090	Srednja	
ZADAR	0,0506	Visoka	-0,0006	Srednja	
ŠIBENIK	0,0582	Visoka	0,0021	Srednja	
VODNJAN	0,0632	Visoka	-0,0006	Srednja	
METKOVIĆ	0,0632	Visoka	-0,0081	Srednja	
VARAŽDIN	0,0674	Visoka	-0,0076	Srednja	
VRGORAC	0,0791	Visoka	0,0038	Srednja	
VALPOVO	0,0867	Visoka	-0,0016	Srednja	
DELNICE	0,0971	Visoka	-0,0093	Srednja	
RIJEKA	0,1461	Visoka	-0,0106	Srednja	
HRVATSKA KOSTAJNICA	0,2337	Visoka	-0,0119	Srednja	
SUPETAR	0,2715	Visoka	0,0040	Srednja	
BAKAR	-0,1090	Niska	0,0373	Visoka	
CRES	-0,0998	Niska	0,0211	Visoka	
GOSPIĆ	-0,0903	Niska	0,0224	Visoka	
PETRINJA	-0,0783	Srednja	0,0193	Visoka	
VINKOVCI	-0,0744	Srednja	0,0220	Visoka	
PRELOG	-0,0632	Srednja	0,0287	Visoka	
LIPIK	-0,0402	Srednja	0,0168	Visoka	
VRLIKA	-0,0176	Srednja	0,0254	Visoka	
KRK	0,0505	Visoka	-0,0217	Visoka	
MALI LOŠINJ	0,0641	Visoka	-0,0150	Visoka	
GAREŠNICA	0,0649	Visoka	-0,0223	Visoka	
KUTJEVO	0,0790	Visoka	-0,0251	Visoka	
BENKOVAC	0,0855	Visoka	-0,0211	Visoka	
OPATIJA	0,0983	Visoka	-0,0302	Visoka	
RAB	0,1313	Visoka	-0,0154	Visoka	
ZLATAR	0,1426	Visoka	-0,0326	Visoka	
OBROVAC	0,1428	Visoka	-0,0339	Visoka	
PLETERNICA	0,1960	Visoka	-0,0423	Visoka	
ILOK	0,1961	Visoka	-0,0321	Visoka	
DONJI MIHOLJAC	0,2104	Visoka	-0,0338	Visoka	
KNIN	0,2105	Visoka	-0,0404	Visoka	
NOVI VINODOLSKI	0,2207	Visoka	-0,0335	Visoka	
PLOČE	0,2709	Visoka	-0,0369	Visoka	
ČABAR	0,2823	Visoka	-0,0411	Visoka	
OTOK	0,2862	Visoka	-0,0271	Visoka	
OMIŠ	0,2911	Visoka	-0,0345	Visoka	
BIOGRAD NA MORU	0,3089	Visoka	-0,0359	Visoka	
TROGIR	0,3588	Visoka	-0,0687	Visoka	
OTOČAC	0,3761	Visoka	-0,0473	Visoka	
ORAHOVICA	0,4470	Visoka	-0,0903	Visoka	

Izvor: Izračun i prikaz autora

Budući da sama brzina nije dovoljan indikator, a kako bi se u potpunosti stekla slika o učinkovitosti gradova u plaćanju obveza, dodana je i kategorija Oznaka smjera.

Naime, uspoređeno je prosječno stanje zavisne varijable (*default_proxy*) u periodu od 2015. do 2018. godine s početnim stanjem iste varijable u 2014. godini. Pozitivan rezultat ukazuje na loš smjer odnosno na činjenicu da se tijekom promatranog razdoblja iznos dospjelih, neplaćenih obveza povećavao (ne nužno linearnom dinamikom) te je takav smjer označen crvenom strelicom, usmjerenom prema dolje. Pozitivnim se može ocijeniti trend smanjivanja dospjelih, neplaćenih obveza te je stoga takav smjer prikazan zelenom strelicom, usmjerenom prema gore. Najbolji je dokaz tome Orahovica koji je s visokom početnom vrijednosti uz visoku brzinu pozitivno usmjerenu, promatrani period započeo s 52,8 % dospjelih, neplaćenih obveza te da bi, uz kontinuiran pad u petogodišnjem razdoblju, 2018. godinu završio na svega 1,6 %. Stagnacija, odnosno situacija u kojoj nema značajnih promjena između dospjelih, neplaćenih obveza na početku razdoblja te prosječnih dospjelih neplaćenih obveza u nastavku razdoblja označena je žutom strelicom usmjerenom u desnu stranu. Stagnacija može biti dvojako ocjenjena. Naime, stagnacija kod gradova koji na početku razdoblja nisu imali neplaćenih obveza je pozitivna, ali kod gradova koji su imali značajnije vrijednosti dospjelih, neplaćenih obveza ne može biti ocjenjena pozitivno (npr. Zadar ili Valpovo).

Zanimljivo je primijetiti kako su Zagreb i Osijek imali gotovo jednaku početnu vrijednost (niska razina) te istu kategoriju brzine promjene (srednja brzina), ali su zbog suprotnih smjerova postigli različite rezultate. Naime, Grad Zagreb je 2018. godinu završio s vrijednosti zavisne varijable (*default_proxy*) od 1,94 %, dok je Osijek istu godinu završio s 0,23 %.

Skupina gradova koju čine Bakar, Cres i Gospić izdvaja činjenica da su imali vrlo dobru polazišnu poziciju, odnosno vrlo nisku razinu dospjelih, neplaćenih obveza u 2014. godini (ispod 0,5 %). Nažalost, visoka dinamika kretanja u lošem smjeru rezultat je snažnog porasta dospjelih, neplaćenih obveza koje su primjerice kod Bakra, nakon nekoliko godina bez dospjelih, neplaćenih obveza, u 2018. godini iznosile visokih 19 %.

Loše pokazatelje imaju Donji Miholjac i Čabar. Naime, oni su imali visoku razinu dospjelih, neplaćenih obveza u 2014., te dodatni rast udjela dospjelih, neplaćenih obveza u ukupnih rashodima i izdatcima, osobito u 2016. i 2017. godini. Unatoč značajnom smanjenju navedenog pokazatelja u posljednjoj godini promatranog razdoblja, pokazatelji nisu jednakovrijedni. Loše pokazatelje ima, primjerice, i Supetar. Visoka razina početne vrijednosti (30,9 %) te srednja razina dinamike kretanja u lošem smjer rezultat je porasta nemogućnosti pravovremenog plaćanja obveza te konačne vrijednosti zavisne varijable (*default_proxy*) u iznosu od 46,6 %.

Kako bi ispitali koji čimbenici doprinose bržem smanjenju neplaćenih obveza (*default_proxy*) na razini grada, provedena je korelacijska analiza u kojoj su ispitivani prediktori navedeni u tablici br. 81. Ti prediktori izračunati su kao aritmetička sredina tijekom razdoblja 2014. do 2018. godine budući da su trendovi u promatranom razdoblju promjenjivi u promatranim gradovima te se smatra kako aritmetička sredina prediktora u promatranom razdoblju najbolje aproksimira procjenu kretanja prediktorskih varijablā.

Tablica 81. Deskriptivan opis nezavisnih varijablā

Varijabla	Aritmetička sredina	Standardna pogreška aritmetičke sredine	Standardna devijacija	Min	Max
ppor_pp'	0,4810	0,010	0,22	0,11707	0,78
mpp_pp'	0,0783	0,009	0,00	0,10560	0,66
okz_uo'	0,4010	0,023	0,00	0,27126	0,91
potp_pp'	0,2760	0,016	0,07	0,18370	1,28
ki_ko'	13,032	1,335	0,31	15,11202	140,95
got_rp'	0,1645	0,012	0,00	0,14260	0,66
trans'	3,2310	0,107	0,20	1,21550	5,40

Izvor: Izračun i prikaz autora

Prema tablici br. 82, može se vidjeti kako su veliki gradovi (n=25) imali veća inicijalna dugovanja u 2014. godini ($r = 0,192$, $p < 0,05$), isto tako je vidljivo da je usporena dinamika otplate dugovanja ($r = -0,206$, $p < 0,05$). Nadalje, osim veličine grada mjerene po broju stanovnika, početnoj razini dugovanja doprinijele su i varijable *mpp_pp'* ($r = 0,652$, $p < 0,05$) i *potp_pp'* ($r = 0,261$, $p < 0,05$) kao pozitivni prediktori, te *ppor_pp'* ($r = -0.241$, $p < 0,05$), *okz_uo'* ($r = -0.256$, $p < 0,05$), *ki_ko'* ($r = -0,281$, $p < 0,05$) i *trans'* ($r = -0,256$, $p < 0,05$) kao negativni prediktori.

Prosječna vrijednost udjela prihoda od poreza u prihodima poslovanja za promatrano vremensko razdoblje (*ppor_pp'*) i prosječna vrijednost udjela obveza za kredite i zajmove u ukupnim obvezama (*okz_uo')* statistički su značajno povezane s nižim razinama vrijednosti zavisne varijable (*default_proxy*) na početku promatranog vremenskom perioda ($r = -0,241$, $p < 0,01$; $r = -0,256$, $p < 0,01$), ali statistička značajnost nije zabilježena u povezanosti između varijablā i dinamike kretanja zavisne varijable ($r = 0,159$, $p > 0,05$; $r = 0,165$, $p > 0,05$).

Drugim riječima, trend smanjenja ili povećanja zavisne varijable (*default_proxy*) ne ovisi o *ppor_pp'* varijabli kao ni o *okz_uo'* varijabli gradova odnosno na temelju navedenih varijablā ne može se predvidjeti kojom će se brzinom smanjivati dospjele, neplaćene obveze.

Tablica 82. Koeficijenti korelacije za početnu vrijednost i dinamike kretanja zavisne varijable u odnosu na nezavisne varijable

	Početna vrijednost	**Dinamika kretanja**
Veliki gradovi (> 35 000 stanovnika, n = 17)	0,130	-0,140
Veliki gradovi (n = 25)	**0,192***	**-0,206***
ppor_pp'	**-0,241****	0,159
mpp_pp'	**0,652****	**-0,444****
okz_uo'	**-0,256****	0,165
potp_pp'	**0,261****	**-0,235****
ki_ko'	**-0,281****	**0,256****
got_rp'	-0,120	0,041
trans'	**-0,256****	**0,188***

Izvor: Izračun i prikaz autora

*Korelacija statistički značajna na razini značajnosti od 5 %,
** Korelacija statistički značajna na razini značajnosti od 1 %.

Prosječna vrijednost omjera kratkotrajne imovine i kratkoročnih obveza (*ki_ko'*) i prosječna vrijednost ocjene transparentnosti (*trans'*) statistički su značajno povezane s nižim razinama vrijednosti zavisne varijable (*default_proxy*) na početku promatranog vremenskom perioda (r = -0,281, p < 0,01; r = -0,256, p < 0,01), uz statistički značajnu pozitivnu povezanost varijablā s dinamikom kretanja zavisne varijable (r = 0,256, p < 0,01; r = 0,188, p < 0,05). Navedeno znači kako trend smanjenja ili povećanja zavisne varijable (*default_proxy*) ovisi o varijablama gradova *ki_ko'* i *trans'*. Zbog iskazane pozitivne povezanosti, gradovi s većim omjerom kratkotrajne imovine u odnosu na kratkoročne obveze te gradovi koji su transparentnije ocjenjeni, brže su smanjivali dospjele, neplaćene obveze. Drugim riječima, brža je dinamika smanjenja dugovanja što su transparentnije gradovi ocijenjeni.

S druge strane, gradovi s visokom prosječnom vrijednosti varijable omjera prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp'*) inicijalno su imali veći iznos dospjelih, neplaćenih obveza (r = 0,652, p < 0,01), dok su u promatranom razdoblju imali sporiju (statistički značajnu) dinamiku smanjivanja dospjelih obveza (r = -0,444, p < 0,01).

Prosječna vrijednost omjera potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp'*) statistički je značajno povezana s nižim razinama vrijednosti zavisne varijable (r = 0,261, p < 0,01) u 2014. godini uz (statistički značajnu) sporiju dinamiku smanjenja zavisne varijable (r = -0,235, p < 0,01).

Uzevši u obzir ove dvije varijable (*mpp_pp'* i *potp_pp'*) koje su obje statistički značajno povezane s dinamikom kretanja zavisne (temeljem visine korelacije), omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp'*) bolji je indikator budućih promjena.

Prosječna vrijednosti omjera gotovine i rashoda poslovanja (*got_rp'*) nije statistički značajno povezana s vrijednostima zavisne varijable (*default_proxy*) u 2014. godini (r = -0,120, p > 0,05) te nije utvrđena ni statistički značajna povezanost s dinamikom kretanja zavisne varijable (r = 0,041, p > 0,05).

Rezultati tablice br. 82 ukazuju na opravdanost postavljanja višestrukog regresijskog modela s hijerarhijskim pristupom u odabiru nezavisnih varijablā. Hijerarhijski pristup odabira varijabli slijedi skupine utvrđene u teorijskoj strukturi disertacije kada su prilikom podjele čimbenika koji utječu na nemogućnost plaćanja dospjelih obveza oni razvrstani u tri skupine: *Financije i proračun, Likvidnost i dug* te *Stanovništvo*. Sve nezavisne varijable međusobno nisu visoko korelirane (r < 0,426) što ukazuje da model nije opterećen problemom multikolinearnost.

Provedene su dvije višestruke hijerarhijske regresijske analize u kojima su za zavisne varijable postavljene nove modelske varijable:

- Početna vrijednost omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*intercept*).
- Dinamika kretanja omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*slope*).

Za oba testirana modela provjerene su pretpostavke o postojanju multikolinearnosti regresijske analize. Pokazatelji *VIF* (<1,584) i *tolerance* (>0,63) ne donose sumnje u postojanje multikolinearnih prediktora, a Durbin-Watsonov test ima prihvatljivu valjanost (2,215 i 2,226) stoga je moguće zaključiti kako početne pretpostavke regresijske analize o nepostojanju multikolinearnosti i autokorelacije nisu narušene. Opravdanost provođenja višestruke hijerarhijske regresijske analize potvrđena je i izračunom minimalne veličine uzorka primjenom programa G*Power3 (Faul, F. i suradnici, 2007; Faul, F. i suradnici 2009).

Za uočavanje efekta veličine 0,15 (srednji efekt) uz razinu značajnosti od 0,05 i snagu 0,8, minimalna potrebna veličina uzorka za sedam prediktorskih varijablā je 104 jedinica u uzorku.

Postupak modeliranja u hijerarhijskom regresijskom modelu započinje unosom prve skupine varijabla *Financije i proračun* (Model 1), zatim je slijedila i druga skupina varijabla *Likvidnost i dug* (Model 2) te na kraju varijabla iz treće skupine varijabla *Stanovništvo* (Model 3). Rezultati hijerarhijske regresijske analize nalaze se u tablici br. 83 (svi rezultati provedene analize dostupni u prilozima br. 6 i br. 7).

Tablica 83. Višestruki hijerarhijski regresijski modeli

	Višestruki hijerarhijski model: početna vrijednost (*intercept*)				**Višestruki hijerarhijski model: dinamika kretanja (*slope*)**			
	ß	**R^2**	**ΔR^2**	**ΔF**	**ß**	**R^2**	**ΔR^2**	**ΔF**
Model 1		0,446	0,446	50,339***		0,206	0,206	16,187***
ppor_pp'	-0,145*				0,094			
mpp_pp'	0,630***				-0,430***			
Model 2		0,507	0,061	3,761**		0,283	0,077	3,246*
ppor_pp'	-0,115				0,067			
mpp_pp'	0,607***				-0,408***			
okz_uo'	-0,042				-0,011			
potp_pp'	0,161*				-0,192*			
ki_ko'	-0,169*				0,213*			
got_rp'	0,138				-0,155			
Model 3		0,510	0,003	0,688		0,284	0,001	0,239
ppor_pp'	-0,094				0,052			
mpp_pp'	0,605***				-0,406***			
okz_uo'	-0,037				-0,015			
potp_pp'	0,153*				-0,186*			
ki_ko'	-0,161*				0,207*			
got_rp'	0,140				-0,156			
trans'	-0,059				0,042			

Izvor: Izračun i prikaz autora

* p < 0,05, ** p < 0,01, *** p < 0,001

U tablici br. 83 zapisani su standardizirani regresijski koeficijenti. Objašnjenost varijance varijablā **Modela 1** (Financije i proračun) iznosi 44,6 % za početnu vrijednost (*intercept*), a 20,6 % za dinamiku kretanja (*slope*).

Prosječna vrijednost omjera prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp'*) ima statistički značajnu prediktivnu snagu za obje zavisne varijable (ß = 0,630; p < 0,001 te ß = -0,430; p < 0,001), dok prosječna vrijednost udjela prihoda od poreza u prihodima poslovanja (*ppor_pp'*) ima prediktivnu sposobnost prema početnoj vrijednosti kao zavisnoj varijabli (ß = -0,145; p < 0,05).

Nastavljajući se na teorijske koncepte u regresijski model pridružene su varijable *Likvidnosti i duga*, odnosno varijable druge skupine, tj. **Modela 2**. Dodavanjem novih varijablā, koeficijent determinacije povećao se za 6,1 % uz statistički značajnu promjenu F-omjera (p < 0,01) u hijerarhijskom modelu sa zavisnom varijablom početna vrijednost *(intercept*), a povećanje koeficijenta determinacije u drugom hijerarhijskom modelu sa zavisnom varijablom dinamika kretanja (*slope*) iznosi 7,7 % uz statistički značajnu promjenu F-omjera (p < 0,05).
U Modelu 2 prosječna vrijednost omjera prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp'*) i dalje ima najveću prediktivnu sposobnost u usporednom prikazu oba višestruka hijerarhijska modela sa zadržanom statistički značajnom razlikom manjom od 1 % (ß = 0,607 te ß = 0,408). Za varijable iz skupine *Likvidnost i dug* uočena je statistički značajna prediktivna sposobnost u oba hijerarhijska modela za prosječnu vrijednost omjera potraživanja za prihode poslovanja i prihoda poslovanja (ß = 0,161; p < 0,05 te ß = -0,192; p < 0,05) i prosječna vrijednost omjera kratkotrajne imovine i kratkoročnih obveza (ß = -0,169; p < 0,05 te ß = 0,213; p < 0,05). Ukupna objašnjenost varijance početne vrijednosti (*intercept)* temeljem prediktorskih varijablā Modela 2 iznosi 50,7 %. Ukupna objašnjenost varijance dinamike kretanja (*slope*) temeljem prediktorskih varijablā Modela 2 iznosi 28,3 %.

U posljednjem koraku hijerarhijskog regresijskog modela unesena je skupina varijabla *Stanovništvo*, odnosno varijabla transparentnost gradova. Koeficijent determinacije u **Modelu 3** iznosi 51,0 %, ali njegova promjena u odnosu na prethodne modele nije statistički značajna (p > 0,05). Model 3 nije promijenio statistički značajnu prediktivnu sposobnost u predviđanju zavisnih varijablā identificiranih u Modelu 2.

Sva tri modela pokazuju statistički značajnu ulogu odabranih prediktora (nezavisnih varijablā) u objašnjenju varijance zavisne varijable analiziranog višestruko hijerarhijskog modela s obzirom na to da je F-omjer za sva tri modela statistički značajan.

Konačan model pokazuje dobru eksploratornu snagu varijablā *mpp_pp'*, *potp_pp'* i *ki_ko'* u objašnjenju varijacija zavisnih varijablā. Sažeti prikaz modela nalazi se na slici br. 19 (svi rezultati provedene analize dostupni u prilogu br. 8).

Slika 19. Statistička značajnost prediktora u modeliranju *početne vrijednost i dinamike kretanja*

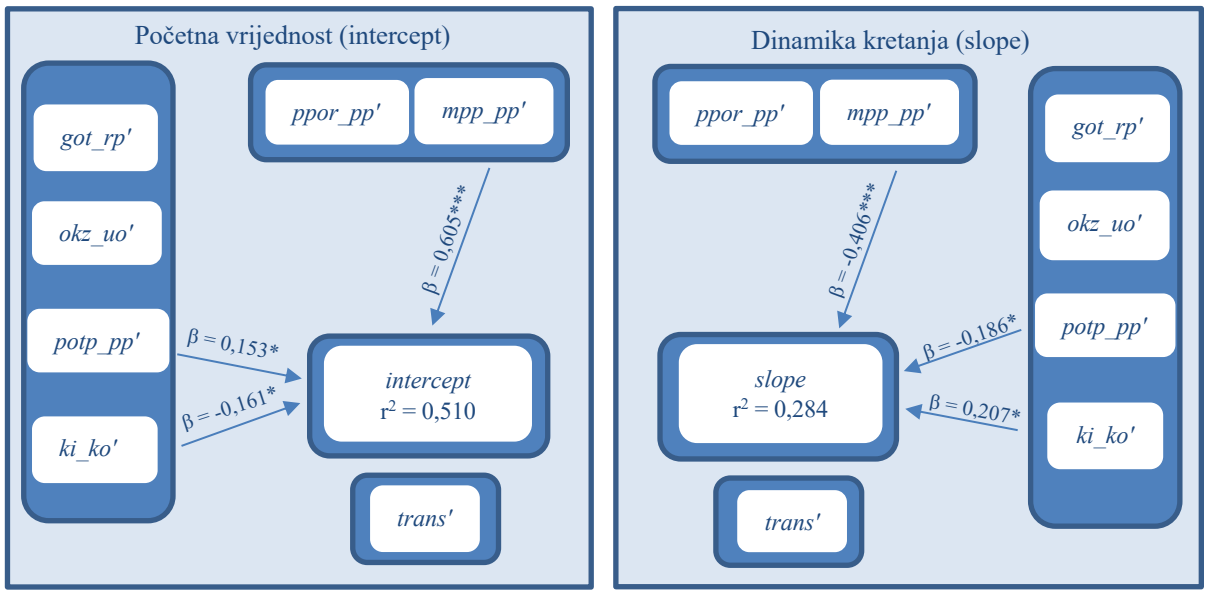

Izvor: Izračun i prikaz autora

Nakon pojašnjenih regresijskih modela kojima je za cilj bilo predviđanje početnih vrijednosti i dinamike kretanja nemogućnosti plaćanja dospjelih obveza, pristupljeno je modeliranju nemogućnosti plaćanja obveza gradova temeljem izračuna *defaulf_proxy'* kao zavisne varijable (u izračunu su sudjelovale vrijednosti zavisnih varijablā za sve analizirane godine). Provedena višestruka regresijska analiza pokazuje kako varijabla ocjena transparentnosti gradova, udio obveza za kredite i zajmove u ukupnim obvezama i omjer gotovine i rashoda poslovanja nisu statistički značajno povezane sa zavisnom varijablom te se pristupilo testiranju konačnog regresijskog modela.

Višestruki regresijski model kojemu je zavisna varijabla prosječni omjer dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy'*) i nezavisnih varijablā: prosječni udio prihoda od poreza u prihodima od poslovanja (*ppor_pp'*), prosječni omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp'*), prosječni omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp'*) te prosječni omjer kratkotrajne imovine i kratkoročnih obveza (*ki_ko'*) donosi objašnjenost varijacija 60,1 % ($F_{4,123} = 46{,}283$, $p < 0{,}001$). Objašnjenost varijance modela govori o visokoj prediktivnoj valjanosti modela (prilog br. 8).

Testirani model ne donosi sumnje u narušenu pretpostavku o multikolinearnosti (VIF < 1,194, tolerance > 0,837) i autokorelaciji (Durbin-Watson = 2,218) te je opravdano modeliranje zapisano jednadžbom koja sadrži vrijednosti nestandardiziranih koeficijenata regresije:

$$default_proxy' = 0{,}093 - 0{,}136ppor_pp' + 0{,}587mpp_pp' + 0{,}071potp_pp' - 0{,}001ki_ko' + 0{,}120\varepsilon$$

Vrijednosti procijenjenih koeficijenata regresijskog modela zapisane su u nestandardiziranom obliku te svaki od koeficijenata ima statistički značajnu prediktivnu sposobnost u postavljenom modelu. Postavljena modelska jednadžba omogućava istraživačima i praktičarima da na temelju prediktora modela kreiraju procjenu nemogućnosti plaćanja dospjelih obveza gradova u nekom od narednih razdoblja. Vrijednosti procijenjenih koeficijenta konačnog modela sažeto je prikazan slikom br. 20.

Slika 20. Statistička značajnost prediktora u konačnom modelu

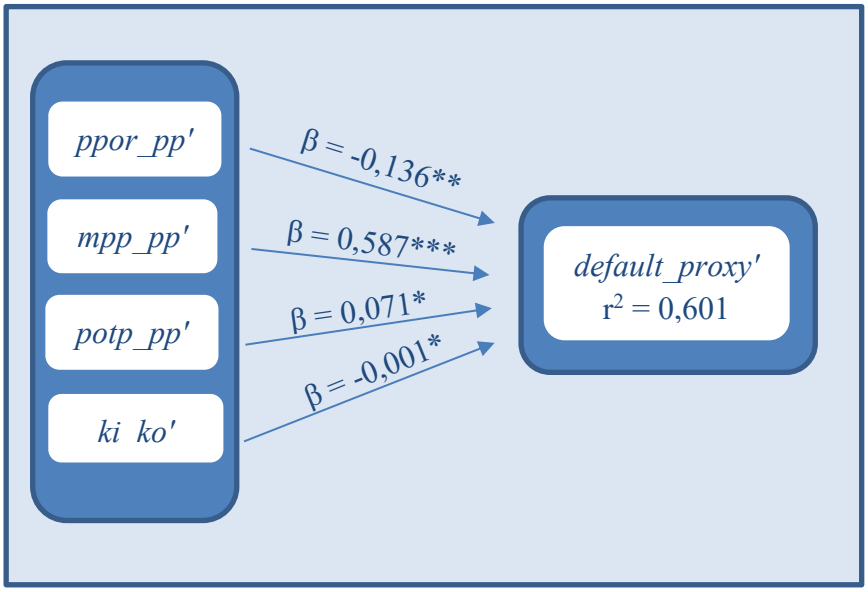

Izvor: Izračun i prikaz autora

Temeljem provedenih analiza, može se zaključiti da su sve predložene hipoteze ne odbacuju. Naime, hipoteza H1 ne odbacuje se budući su karakteristike financija i proračuna statistički značajno povezane s neplaćanjem dospjelih obveza gradova. Udio prihoda od poreza u prihodima poslovanja (*ppor_pp*) i omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*) osim povezanosti imaju i značajnu prediktivnu funkciju. Sve četiri izdvojene varijable iz skupine ¨Likvidnost i dug¨ statistički su značajno povezane s neplaćanjem dospjelih obveza, a varijable omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*) i omjer kratkotrajne imovine i kratkoročnih obveza (*ki_ko*) imaju i prediktivna svojstva čime se i hipoteza H2 ne odbacuje.

Iako nema prediktivnu sposobnost, ocjena transparentnosti (*trans*) statistički je značajno povezana sa zavisnom varijablom čime se i hipoteza H3 ne odbacuje. T-testom nezavisnih uzoraka utvrđeno je da se hipoteza H4, prema kojoj veliki gradovi imaju statistički značajno manju izloženost za nemogućnost plaćanja dospjelih obveza od ostalih gradova, ne odbacuje. Odluka o hipotezama prikazana je i u tablici br. 84.

Tablica 84. Odluke o hipotezama

Hipoteza	Opis	Varijabla	Odluka o hipotezi
H1	Karakteristike financija i proračuna gradova statistički su značajno povezane s neplaćanjem dospjelih obveza gradova.	Udio prihoda od poreza u prihodima poslovanja (*ppor_pp*)	*Ne odbacuje se*
		Omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*)	*Ne odbacuje se*
H2	Karakteristike likvidnosti i duga gradova statistički su značajno povezane s neplaćanjem dospjelih obveza gradova.	Udio obveza za kredite i zajmove u ukupnim obvezama (*okz_uo*)	*Ne odbacuje se*
		Omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*)	*Ne odbacuje se*
		Omjer kratkotrajne imovine i kratkoročnih obveza (*ki_ko*)	*Ne odbacuje se*
		Omjer gotovine i rashoda poslovanja (*got_rp*)	*Ne odbacuje se*
H3	Socioekonomske karakteristike gradova statistički su značajno povezane s neplaćanjem dospjelih obveza gradova.	Ocjena transparentnosti (*trans*)	*Ne odbacuje se*
H4	Veliki gradovi imaju statistički značajno manju izloženost za nemogućnost plaćanja od ostalih gradova u Republici Hrvatskoj.		*Ne odbacuje se*

Izvor: Prikaz autora

7.2. Rasprava o rezultatima istraživanja

Plaćanje obveza gradova u Republici Hrvatskoj na vrijeme i u punom iznosu, iako u potpunosti zakonom regulirano, i dalje nije u pravom fokusu znanstvenoistraživačke i gospodarske prakse. Istraživačke studije domaćih istraživača (Bajo, Primorac 2009; Bajo, Primorac 2010; Posedel, Primorac 2012; Vlah Jerić, Primorac 2017), ukazivale su na nerazumijevanje lokalnih jedinica kad su u pitanju uravnoteženi proračunski prihodi s proračunskim rashodima i potreba za kvantificiranjem kreditnog rizika lokalnih jedinica.

S obzirom na potrebu kvantificiranja navedenog rizika, Posedel i Primorac (2012: 334) u svom istraživanju kreirali su varijablu koja može aproksimirati kreditni rizik gradova, a koja se sastoji od omjera dospjelih nepodmirenih obveza nastalih unutar godine dana i ukupnih obveza dospjelih u toj godini. U doktorskoj disertaciji predložena varijabla definirana je kao zavisna (*default_proxy*). U prethodnim istraživanjima testirana je i dokazana povezanost nemogućnosti plaćanja dospjelih obveza i varijablā udio od poreza i prireza na dohodak u prihodima poslovanja, udio neto operativnog salda u prihodima poslovanja, omjer neto financijske imovine i prihoda poslovanja te omjer gotovine i rashoda poslovanja. Navedene varijable uvrštene su i u istraživački okvir doktorske disertacije s definiranom ulogom nezavisnih varijablā.

Kako je prikazano u analizama poglavlja 7., gotovo svi gradovi (njih 116 od 128), u 2018. godini nisu platili dio svojih obveza na vrijeme te je ukupni iznos takvih obveza bio veći od 684 milijuna kuna. S obzirom na relativno stabilne izvore prihoda, prosječni udio dospjelih nepodmirenih obveza u ukupnim godišnjim rashodima i izdatcima (zavisna varijabla - *default_proxy*) visokih je 8,14 % u petogodišnjem, istraživanjem obuhvaćenom, razdoblju. Istraživanjem su obuhvaćeni različiti čimbenici koji bi mogli imati utjecaja na nemogućnost plaćanja dospjelih obveza. Temeljem dosadašnjih znanstvenih istraživanja, ali i dokumentirane poslovne prakse velikih rejting agencija, izdvojeni i testirani čimbenici podijeljeni su u tri grupe uz testiranje povezanosti sa zavisnom varijablom.

U grupi *Financije i proračun*, dokazana je statistički značajna povezanost između zavisne varijable i udjela prihoda od poreza u prihodima poslovanja (*ppor_pp*: $r_1 = -0{,}239$, $r_2 = -0{,}227$, $r_3 = -0{,}215$, $r_4 = -0{,}277$; $p < 0{,}05$) te omjera prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*: $r_1 = 0{,}663$, $r_2 = 0{,}757$, $r_3 = 0{,}752$, $r_4 = 0{,}743$, $r_5 = 0{,}404$; $p < 0{,}001$) i na taj je način utvrđeno da se hipoteza H1 ne odbacuje. Naime, promjene u navedena dva čimbenika utječu na promjene u neplaćanju dospjelih obveza gradova. Povećanje udjela prihoda od poreza te smanjenje prenesenog manjka poslovanja, pozitivno djeluju na pravovremeno plaćanje obveza gradova, odnosno utječu na smanjenje zavisne varijable. Budući da negativna korelacija varijable *ppor_pp* sa zavisnom varijablom nije očekivana, navedeni bi odnos naknadno trebalo dodatno istražiti.

Pretpostavka kako postoji statistički značajna povezanost između neplaćanja dospjelih obveza gradova i karakteristika grupe *Likvidnosti i dug* zapisana je u H2 hipotezi.

Navedena se hipoteza ne odbacuje budući da je zabilježeno kako su promjene kod čak četiri nezavisne varijable navedene skupine statistički značajno povezane s promjenom zavisne varijable: udio obveza za kredite i zajmove u ukupnim obvezama *(okz_uo*: $r_2 = -0{,}326$, $r_4 = -0{,}252$, $r_5 = -0{,}257$; $p < 0{,}01$), omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*: $r_2 = 0{,}257$, $r_3 = 0{,}323$, $r_4 = 0{,}232$; $p < 0{,}01$), omjer kratkotrajne imovine i kratkoročnih obveza (*ki_ko*: $r_1 = -0{,}232$, $r_2 = -0{,}199$, $r_3 = -0{,}275$, $r_4 = -0{,}386$; $p < 0{,}05$) te omjer gotovine i rashoda poslovanja (*got_rp*: $r_3 = -0{,}198$, $r_4 = -0{,}205$; $p < 0{,}05$). Veći udio obveza za kredite i zajmove u ukupnim obvezama, korelira sa smanjenjem vrijednosti zavisne varijable, iz čega se može izvući zaključak da se u situaciji porasta zaduženosti čelni ljudi gradova više fokusiraju na pravovremeno ispunjenje svih obveza. Također se radi o neočekivanom odnosu (negativno koreliranom), te bi i navedeni odnos trebalo naknadno dodatno istražiti. Porast potraživanja neminovno smanjuje likvidnost gradova i utječe na plaćanje obveza, a što je ovim istraživanjem i potvrđeno. Smanjenje omjera kratkotrajne imovine i kratkoročnih obveza te smanjenje omjera gotovine u rashodima poslovanja također ukazuje na smanjenu likvidnost koja je prema istraživanju povezana s povećanjem nemogućnosti plaćanja obveza.

Od četiri nezavisne varijable testirane kako bi se dokazala treća hipoteza (H3) samo je jedna socioekonomska karakteristika gradova statistički značajno povezana s neplaćanjem dospjelih obveza gradova, a to je ocjena transparentnosti (*trans*: $r_1 = -0{,}204$, $r_4 = -0{,}306$, $r_5 = -0{,}189$; $p < 0{,}05$). Evidentno je da gradovi koji svojim građanima omogućavaju veći uvid u financijske podatke, odnosno raspodjelu proračunskih sredstava, opreznije upravljaju proračunskim sredstvima te samim time i smanjuju mogućnost neplaćanja obveza na vrijeme.

Veličina grada čimbenik je po kojem se gradovi razlikuju s obzirom na nemogućnost plaćanja obveza. Naime, veliki gradovi u Republici Hrvatskoj (veći od 35 000 stanovnika) te gradovi sjedišta županija ($n = 25$) imaju statistički značajno manju vjerojatnost nemogućnosti plaćanja od manjih gradova ($t = -5{,}219$, $df = 346{,}511$, $p < 0{,}001$). Razloge zbog kojih manji gradovi imaju veću vjerojatnost prije svega treba tražiti u većoj ovisnosti o državnoj pomoći te o manjoj fleksibilnosti u slučaju financijskih neprilika (pada prihoda, nepovoljnih sudskih presuda i sl.).

Odnos odabranih sedam nezavisnih varijablā i zavisne varijable nemogućnost plaćanja dospjelih obveza (*default_proxy*), kroz istraživanjem obuhvaćeno petogodišnje razdoblje, ispitan je primjenom regresijske analize panel-podataka na način da se prate odnosi dviju varijabli kroz vrijeme.

U skupini *Financije i proračun*, utvrđena je umjereno, pozitivna povezanost omjera prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*) i zavisne varijable (*default_proxy*) te model postiže dobre indekse pogodnosti ($\chi 2$ = 48,203, df = 25, p < 0,01, CFI = 0,984, TLI = 0,972, RMSEA = 0,085, SRMR = 0,038). Dodatno, navedena nezavisna varijabla predviđa kretanje zavisne varijable, ali u negativnom smjeru. Sve navedeno znači da visoka razina prenesenog manjka povećava nemogućnost plaćanja dospjelih obveza u istoj godini, ali i da već sljedeće godine dolazi do smanjenja zavisne varijable (*default_proxy*).

U skupini *Likvidnost i dug* odnos udjela obveza za kredite i zajmove u ukupnim obvezama (*okz_uo*) i zavisne varijable (*default_proxy*) ima nisku, negativnu povezanost u 2014., 2015. i 2017. godini. Jednaka takva povezanost postoji i za odnos omjera kratkotrajne imovine i kratkoročnih obveza (*ki_ko*) u 2014., 2016. i 2017. godini. Naime, veća opterećenost gradova kreditima i zajmovima, te bolji odnos kratkotrajne imovine s kratkoročnim obveza, rezultira ažurnijim podmirenjem dospjelih obveza. Niska, pozitivna povezanost, statistički značajna u periodu od 2015. do 2017. godine, zabilježena je za omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*) i zavisne varijable (*default_proxy*). Gotovo zanemariva povezanost zabilježena je za omjer gotovine i rashoda poslovanja (*got_rp*) i zavisne varijable (*default_proxy*), a povezanost varijable *trans* iz skupine *Stanovništvo* sa zavisnom varijablom (*default_proxy*) nije statistički značajna.

Za ispitivanje dinamike kretanja zavisne varijable korištena je analiza latentnog rasta krivulje. Kroz navedenu analizu izračunate su dvije nove varijable: *intercept* (početna vrijednosti zavisne varijable) s uključenim svim godinama zavisne varijable, te *slope* (dinamika kretanja zavisne varijable) bez uključene zavisne varijable iz 2017. Naime, gradovi su se značajno razlikovali s obzirom na omjer dospjelih, nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) u prvoj godini promatranog razdoblja, odnosno imali su različitu polazišnu poziciju u promatranom razdoblju. Također, dinamika kretanja im je uglavnom bila različita (izuzmu li se oni gradovi koji su tijekom promatranog razdoblja sve svoje obveze plaćali na vrijeme). Analizom je utvrđena visoka, negativna korelacija *početne vrijednosti* i *dinamike kretanja* (r= -0,842, p < 0,001) odnosno, gradovi s nižim vrijednostima dospjelih neplaćenih obveza u 2014. godini, brže su ih smanjivali u budućim godinama. Analizom je utvrđeno i da je prosječna vrijednost omjera prenesenog manjka prihoda u prihodima poslovanja (*mpp_pp'*) najbolji indikator budućih promjena zavisne varijable (*default_proxy*).

Statistički značajna povezanost s dinamikom kretanja zavisne varijable utvrđena je i za prosječnu vrijednost omjera kratkotrajne imovine i kratkoročnih obveza (*ki_ko'*), zatim za ocjenu transparentnosti (*trans'*) te za prosječnu vrijednost omjera potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp'*).

Početna vrijednost zavisne varijable te njezina dinamika kretanja korištene su, kao zavisne varijable, i u provedbi višestruke hijerarhijske regresije. Naime, modeliranje je provedeno postupnim dodavanjem varijablā po utvrđenim skupinama, prvo varijable iz skupine *Financije i proračun*, zatim su dodane varijable iz skupine *Likvidnost i dug*, a na samom kraju i varijabla iz skupine *Stanovništvo*. S obzirom na već prikazane rezultate prethodnih analiza, bilo je očekivano da će prosječna vrijednost omjera prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp'*) imati značajnu prediktivnu snagu. To očekivanje potvrdili su rezultati regresije (ß = 0,605; $p < 0,001$ te ß = -0,406; $p < 0,001$), ali je statistički značajna prediktivna sposobnost utvrđena i za prosječnu vrijednost omjera potraživanja za prihode poslovanja i prihoda poslovanja (ß = 0,153; $p < 0,05$ te ß = -0,186; $p < 0,05$) te za prosječnu vrijednost omjera kratkotrajne imovine i kratkoročnih obveza (ß = -0,161; $p < 0,05$ te ß = 0,207; $p < 0,05$). Sve tri izdvojene varijable korištene su, kao nezavisne varijable u odnosu sa prosječnim omjerom dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy'*), i za kreiranje konačnog (višestrukog regresijskog) modela koji ima visoku prediktivnu valjanost (objašnjenost varijance na razini 60,1 %).

Tijekom promatranog petogodišnjeg razdoblja omjer dospjelih nepodmirenih obveza u ukupnim rashodima (*default_proxy*) i omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*) imali su slične, nelinearne trendove kretanja. Nakon trenda smanjenja u prve tri godine, u 2017. godini dolazi do naglog rasta obje promatrane varijable. Iako bi navedenu anomaliju trebalo dodatno istražiti (najbolje u duljem vremenskom razdoblju), za pretpostaviti je da je iznenadna promjena trenda rezultat lokalnih izbora koji su se dogodili u svibnju navedene godine odnosno, da je prekomjerna potrošnja rezultat nastojanja da se zadrži vlast ili rezultat realizacije predizbornih obećanja. U posljednjoj godini promatranog razdoblja ponovno je zabilježen trend smanjivanja dospjelih, neplaćenih obveza.

Važno je napomenuti da je najbolji prediktor nemogućnosti pravodobnog izvršavanje obveza gradova omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*) jer je ovaj omjer pokazao svoju stabilnost tijekom čitavog razdoblja, ali i prilikom primjene različitih statističkih metoda.

Varijabla omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*) i varijabla omjer kratkotrajne imovine i kratkoročnih obveza (*ki_ko*) nisu toliko čvrsto povezane sa zavisnom varijablom, odnosno povezanosti ne vrijede za sve promatrane godine.

Uzimajući u obzir sve navedene čimbenike, statistički je dokazano da kvalitetno upravljanje likvidnošću omogućava izvršavanje svih obveza gradova na vrijeme i u punom iznosu. Polazišnu osnovu čine oslanjanje na porezne prihode kao najstabilnije izvore prihoda te uravnotežen proračun koji ne generira manjak poslovanja. Pravodobna naplata svih potraživanja uz kontinuirano održavanje dostatne razine gotovine te adekvatne razine kratkotrajne imovine ključni su za pravodobno podmirenje obveza. Povećana zaduženost, uz odgovarajuće upravljanje likvidnošću, pri tome ne predstavlja značajnu opasnost od nemogućnosti plaćanja. Transparentnost također ima svojevrstan, posredni, utjecaj na likvidnost jer čelnike obvezuje na racionalnije upravljanje financijskih sredstvima.

7.2.1. Ograničenja i nedostatci modela za predviđanje nemogućnosti plaćanja obveza gradova

Model za izračun neplaćanja obveza gradova uvelike ovisi o dostupnosti podataka, odnosno model bi bio sveobuhvatniji kada bi bilo moguće testirati veći set podataka (veći broj varijablā u duljem vremenskom nizu). Naime, dostupni podatci Državnog zavoda za statistiku ne omogućavaju kvalitetniju analizu gospodarskih pokazatelja, jer je najniža razina na kojoj se prikazuju podatci, razina županija. Primjerice, bruto domaći proizvod (BDP) dostupan je samo na razini županija i u trenutku provođenja analize bili su dostupni podatci zaključno s 2017. godinom. Također, slična je situacija i s robnom razmjenom ili podatcima o bruto i neto plaćama koji se prikazuju samo na razini županija.

Ministarstvo financija promijenilo je metodologiju izračuna podjele sredstava fiskalnog izravnanja te navedeni pokazatelj nije mogao biti uvršten u analizu. Testiranje ove pretpostavke ima svoje teorijsko i praktično uporište te se sugerira praćenje navedene varijable u budućim istraživanjima, jer bi bilo zanimljivo ustanoviti povezanost neplaćanja dospjelih obveza sa stupnjem korištenja navedenih sredstava. Dodatno, dostupni podatci koje objavljuje ministarstvo u određenom dijelu nisu dovoljno detaljni. Naime, prema postojećem kontnom planu ne postoji mogućnost izdvajanja vlastitih namjenskih prihoda, a nisu ni dostupni podatci o troškovima sudskih postupaka za istraživanjem obuhvaćeno razdoblje.

Također, kod prikazivanja podataka o likvidnosti gradova, ne postoje podatci o prosječnim stanjima gotovine i depozita koji se mogu značajno razlikovati od stanja na zadnji dan promatrane godine. Indeks razvijenosti također je pokazatelj koji bi doprinio većem razumijevanju varijacija u zavisnoj varijabli modela. Zbog promjene metodologije izračuna 2018. godine od strane Ministarstva regionalnog razvoja i fondova Europske unije onemogućena je ujednačena usporedba podataka varijable indeksa kroz promatrano vremensko razdoblje obuhvaćeno istraživanjem disertacijom.

Budućim istraživačima preporuča se analiziranje uočenih nedostataka navedenih u doktorskoj disertaciji te metodološko prevladavanje ograničenja koja su postavljena u planiranjima empirijskog istraživanja te vremenskom obuhvatu vremenskih serija.

7.3. Preporuke i smjernice za buduća istraživanja

Neplaćanje obveza teško se može potpuno *iskorijeniti* odnosno nije izvjesno da će u skorije vrijeme svi hrvatski gradovi sve svoje obveze podmirivati na vrijeme i u punim iznosima. Brojni su faktori koji imaju utjecaj na financijske rezultate svih lokalnih jedinica vlasti, ali sistematičnim pristupom ovom problemu može se rizik neplaćanja smanjiti na najmanju moguću, potencijalno i dugoročno prihvatljivu razinu. Stoga se u nastavku iznosi niz preporuka i smjernica za njihovu implementaciju.

7.3.1. Preporuke proizašle iz modela

Model testiran u istraživanju omogućava sveobuhvatniju sliku rizičnosti gradova u Republici Hrvatskoj te čimbenika koji najviše utječu na nemogućnost plaćanja dospjelih obveza gradova. Kako bi se sadašnja, nepovoljna situacija u kojoj se nalaze gradovi promijenila, nužno je promijeniti zakone, pravilnike, ali i sam način postupanja čelnih ljudi gradova koji ponekad lošim odlukama dovedu grad u financijske poteškoće. Svi dionici trebali bi koristiti čimbenike modela i sam model kako bi bolje spoznali svoju financijsku poziciju i adekvatno kvantificirali buduće rizike nemogućnosti plaćanja obveza. Osim ove temeljne preporuke, dodatne preporuke iz ove doktorske disertacije mogu se podijeliti na preporuke koje su usmjerene prema sljedećim važnim dionicima:

- predstavnici zakonodavne i izvršne vlasti (ponajprije Ministarstva financija)
- lokalna samoupravi, tj. gradovi
- financijske institucije.

7.3.1.1. Preporuke za zakonodavnu i izvršnu vlast

Državna vlast, iz perspektive zakonodavne i izvršne vlasti, postavlja okvire za funkcioniranje svih nižih razina vlasti. Odgovorna je za uravnotežen razvoj, za dostatnost financijskih sredstava za financiranje preuzetih odgovornosti svih podređenih razina vlasti, ali i za nesmetano funkcioniranje gradova koje duljom nemogućnošću plaćanja obveza može biti narušeno. Kako bi se unaprijedila pozicija gradova, pripremljene su preporuke zakonodavnoj vlasti. One se mogu se podijeliti u nekoliko osnovnih skupina:

1. prikupljanje i javna dostupnost podataka
2. stručna potpora i nadzor nad aktivnostima gradova
3. uvođenje kreditnog rejtinga za gradove i poduzeća u njihovu vlasništvu.

Prikupljanje i javna dostupnost podataka

Osnovu za upravljanje, pa samim time i za upravljanje nižim razinama vlasti, čine pravodobne i kvalitetne informacije. Resornim ministarstvima i čelnicima lokalnih jedinica potrebno je omogućiti pristup relevantnim podatcima putem dorade postojećih izvještajnih obrazaca. Kako je sve veći naglasak na (su)financiranju projekata iz raznih nacionalnih i EU fondova, potrebna je jasnija razrada kontnog plana vezana za EU projekte i prijenose projektnim partnerima. Naime, trenutno je moguće pratiti prihode, ali ne i rashode (prijenose) u jednoj godini primjerice tvrtkama, neprofitnim udrugama, proračunskim korisnicima i sl. Potrebna je i jasnija razrada kontnog plana u financijskim izvještajima vezana za kapitalne pomoći trgovačkim društvima za otplatu kredita, jer je zasad prema tom principu moguće pratiti samo proračunske korisnike (AOP 237) te za jamstva trgovačkim društvima. Bilo bi vrlo korisno detaljnije razraditi kreditna zaduženja (primjerice na kratkoročne i dugoročne, prema valutama, vrsti kamatne stope i sl.), ali i učestalije pratiti kretanje ukupne zaduženosti (direktne i indirektne). Značajno bi bilo uvesti i izvještaj kojim bi se kontinuirano pratili pokazatelji likvidnosti gradova (primjerice prosječna stanja na osnovnom računu, iskorištenost kratkoročnih kredita, potraživanja za prihode poslovanja, razni omjeri bilančnih pozicija i sl.). Kao što ističu Bajo i Primorac (2014) *nužna je i formalna konsolidacija financijskih izvještaja lokalnih jedinica i trgovačkih društava u njihovu vlasništvu*. Takva konsolidacija omogućila bi sveobuhvatniju sliku financijskog položaja lokalnih jedinica.

Potrebno je omogućiti i Državnom zavodu za statistiku vođenje ažurnije baze o gospodarskim pokazateljima za svaki grad te učestalije objave o procijenjenom broju stanovnika nakon sljedećeg popisa stanovništva planiranog za 2021.godinu.

Uz sve navedeno, potrebno je dodatno digitalizirati te samim time pojednostavniti sam unos podataka od strane gradova te ubrzati agregiranje tih podataka na razini Republike Hrvatske. Nije primjereno agregirane podatke čekati 6 i više mjeseci nakon roka za dostavu podataka koji, u pravilu, gradovi poštuju.

Stručna potpora i nadzor nad aktivnostima gradova

Gradovima je nužno ponuditi i stručnu potporu po pitanju uravnoteženja proračuna i upravljanja likvidnosti, jer evidentno je da su oscilacije i odstupanja od očekivanih vrijednosti prevelika. Navedena se potpora prvenstveno odnosi na edukaciju čelnika gradova po pitanju osnova financijskog upravljanja. Također, država bi trebala učestalije nadzirati gradove te sankcionirati one koji ignoriraju zakonske odredbe ili preporuke resornih ministarstava.

Uvođenje kreditnog rejtinga za gradove i poduzeća u njihovu vlasništvu

Uvođenje kreditnog rejtinga Ministarstva financija za gradove i njihova komunalna poduzeća, temeljenog na jasnim, kvantitativnim i kvalitativnim pokazateljima, omogućilo bi svim dionicima (građanima, čelnim ljudima gradova, ministarstvima, kreditorima i sl.) spoznaju o stvarnoj rizičnosti pojedinih gradova te u konačnici o kvaliteti upravljanja proračunskim sredstvima svakog pojedinog grada. Bajo i Primorac (2009) navode da gradove treba rangirati od nižih prema višim rizicima sposobnosti otplate duga prema ukupnoj ocjeni kreditne sposobnosti (uključujući i komunalna društva u vlasništvu) te da se na taj način rješava problem nepredviđenih rizika, ali i neizravno poboljšava transparentnost zaduživanja lokalnih jedinica, i isto tako objektivnije utvrđuju proračunska ograničenja na zaduživanje i kontrolira njihovo pridržavanje. Navedeni bi rejting trebalo periodično obnavljati te metodološki usavršavati temeljem najnovijih znanstvenih spoznaja i uvažavajući poslovnu praksu najvećih kreditnih rejting agencija. Rangiranje gradova potaknulo bi čelnike gradova sa začelja takve liste da se dodatno potrude te boljim i transparentnijim upravljanjem proračunskim sredstvima zasluže bolji rejting.

7.3.1.2. Preporuke za lokalnu samoupravu

Upravljanje proračunskim sredstvima, uz kontinuirane promjene zakonske regulative koja direktno utječe na prihode gradova, nije jednostavan zadatak. Kako bi se u svakom trenutku gradovi pridržavali zakonskih odredbi, te osigurala potrebna likvidnost za pravovremeno i potpuno plaćanje svih obveza, važno je pratiti ključne čimbenike prikazane u modelu. Ti čimbenici prvenstveno mogu biti rani signali upozorenja poteškoća koje će uslijediti. Preporuke za lokalnu samoupravu mogu se podijeliti u nekoliko skupina:

1. Očuvanje potrebne razine likvidnosti
2. Ažurna naplata potraživanja
3. Racionalno upravljanje rashodovnom stranom proračuna

Jednakovrijednu razinu likvidnosti gradovi će postići usmjerenošću na uravnotežene proračunske prihode i rashode, korištenje kratkoročnih kreditnih sredstava uz maksimalne napore kod ažurne naplate potraživanja. Minimalna odstupanja, čak i povremeni, minimalni proračunski manjak, neće narušiti pravovremeno plaćanje obveza. Dodatno, uravnoteženost proračuna i dobri poslovni rezultati omogućit će većem broju gradova pristup povoljnijim izvorima financiranja. Marković i Dunković (2009) ističu potrebu uključivanja lokalnih jedinica u tijekove međunarodnih fondova i institucija, te bi u budućnosti sredstva tih banaka trebala biti češće korištena za financiranje investicijskih projekata. To će dovesti do dodatnog smanjenja troškova budućeg zaduživanja. Racionalno upravljanje proračunskim sredstvima uključuje i sva druga područja, a osobito rashode za zaposlene, razne donacije i subvencije te provedbu projekata. Potrebno je stoga izbjegavati porast proračunskih trošenja koja nisu pokrivena porastom prihoda (kao što je do sada bio slučaj u izbornim godinama) ili razmjernim iznosom proračunskih primitaka.

7.3.1.3. Preporuke za financijske institucije

Financijske institucije koriste vlastite sustave kvantificiranja kreditnog rizika koji se temelje na kvantitativnim i kvalitativnim čimbenicima. Budući da je svako tržište specifično, a takvi se alati obično rade za cjelokupno tržište koje određena financijska grupacija *pokriva*, spoznaje o ključnim čimbenicima koji utječu na nemogućnost plaćanja dospjelih obveza utvrđene ovim istraživanjem omogućit će *kalibriranje* njihovih sustava procjene kreditnog rizika za tržište Republike Hrvatske.

7.3.2. Smjernice za buduća istraživanja

Buduća istraživanja treba temeljiti na većem obimu podataka odnosno na duljim vremenskim serijama te testiranju većeg broja varijabli. Naime, potrebno je značajnije testirati utjecaj gospodarskih pokazatelja na kretanje nemogućnosti plaćanja obveza gradova. Također, s porastom projekata financiranih iz nacionalnih fondova i fondova EU trebalo bi pratiti njihov utjecaj na financijsku stabilnost lokalnih jedinica.

Poseban su segment u budućim istraživanjima, obveze poduzeća koja su u vlasništvu gradova te ustanova koje su osnovali. Primorac i Poljak svojim su istraživanjem podataka o dugu velikih gradova i njihovih trgovačkih društava za razdoblje od 2012. do 2015. godine potvrdili *tezu o međuovisnosti financijskog poslovanja i zaduživanju lokalnih jedinica posredstvom trgovačkih društava u njihovom vlasništvu* (Primorac, Poljak 2018: 14). Kako gradovi, u pravilu, ne mogu dopustiti stečaj ili likvidaciju tih poslovnih subjekata, važno je i njih obuhvatiti prilikom procjene rizičnosti gradova (neovisno o tome je li im dano jamstvo grada ili ne). Nepravodobnost u podmirenju obveza nekog komunalnog poduzeća, negativno se odražava i na bonitet grada koji je vlasnik istog. Također, zaduženost gradskih poduzeća i ustanova može biti čak i veća od zaduženosti samog grada te predstavljati značajnu prijetnju stabilnosti gradskog proračuna.

Dodatno, u budućim istraživanjima trebalo bi izračunati kreditni rizik za svaki pojedini grad te utvrditi koliko taj izračunati stupanj rizičnosti gradova korelira s ugovorenim cijenama kreditnih zaduženja. Uz to, istraživanja bi trebala obuhvatiti i sve subjektivne okolnosti koje utječu na bolji rejting gradova kod banaka i nižu cijenu zaduživanja (partnerski odnos s gradom, strateško pozicioniranje i sl.).

8. Zaključak

Gradovi u Republici Hrvatskoj ne plaćaju svoje obveze na vrijeme i u punim iznosima. Ukupni iznos dospjelih, neplaćenih obveza dosegnuo je u 2018. godini 684 milijuna kuna, a navedena godina nije izuzetak već pravilo koje se ponavlja tijekom cijelog promatranog razdoblja istraživanja ove doktorske disertacije. Dakle, opsežnim analizama provedenim u disertaciji obuhvaćeni su svi gradovi u Republici Hrvatskoj (njih 128) te petogodišnje vremensko razdoblje koje je započelo 2014. godine, a završilo 2018. godine. Osnovni cilj, koji je u konačnici i postignut, bio je identificirati i testirati sve relevantne financijske i socioekonomske čimbenike kako bi se izdvojile ključne varijable koje su statistički značajno povezane s nemogućnošću pravovremenog plaćanja obveza hrvatskih gradova.

Položaj gradova u strukturi javnog sektora omogućava im utjecaj na važne aspekte funkcioniranja društva u cjelini. Naime, gradovima je povjereno uređenje naselja i stanovanje, te prostorno i urbanističko planiranje kao temeljne pretpostavke razvoja. Nadalje, povjereno im je komunalno gospodarstvo i promet, zatim briga o djeci, odgoj i obrazovanje, kultura, tjelesna kultura i šport, socijalna skrb za potrebite te još mnoge druge važne funkcije. Kako bi gradovi nesmetano provodili sve potrebne aktivnosti, putem vlastitih proračuna, osigurana su im adekvatna sredstva za sve navedeno. Gradovi stoga primaju sredstva od udjela u zajedničkim porezima (porez na dohodak), utvrđuju i naplaćuju vlastite poreze i naknade (prirez porezu na dohodak, porez na potrošnju, porez na korištenje javnih površina, komunalnu naknadu i sl.) ili ostvaruju prihode od vlastite imovine (prodaja ili najam stanova, poslovnih prostora, zemljišta i sl.). Dodatno, država iz svog proračuna izdvaja sredstva za financiranje decentraliziranih funkcija, a gradovima su na raspolaganju i sredstva nacionalnih i EU fondova. O financijskoj snazi gradova najbolje govore podatci da su u 2018. godini ukupni rashodi i izdatci svih gradova iznosili 18,7 milijardi kuna. Financiranje investicijskih aktivnosti gradova zaduživanjem kod poslovnih banaka dosegnulo je u 2018. godini razinu od 3,5 milijarde kuna, što kad se u obzir uzme imovinu gradova koja je iste godine iznosila 97,4 milijarde kuna, uz stabilne izvore financiranja, i dalje gradove ne čini previše opterećenima ili prezaduženima. Socioekonomsku sliku gradova ocrtava kretanje broja stanovnika koje je, u promatranom razdoblju, negativno za sve gradova osim Grada Zagreba (prema procjena 2018. godine je u gradovima živjelo 2,9 milijuna stanovnika) uz istovremeni rast broja zaposlenih na 1,3 milijuna te smanjenje broja nezaposlenih na svega 105 tisuća.

Osnovne smjernice provedenih istraživanja o nemogućnost plaćanja obveza gradova na vrijeme i u punom iznosu u okviru ove disertacije činile su uspostavljene metodologije velikih, svjetskih rejting agencija te provedena domaća i strana istraživanja. Temeljem tih spoznaja potencijalni čimbenici koji utječu na nemogućnost plaćanja obveza gradova podijeljeni u tri kategorije osnovne kategorije: *Financije i proračun*, *Likvidnost i dug* te *Stanovništvo*. Utvrđene su i osnovne hipoteze rada (H1, H2 i H3): karakteristike vezane uz svaku pojedinu kategoriju statistički su značajno povezane s neplaćanjem dospjelih obveza gradova. Kao četvrta hipoteza (H4) testirano je imaju li veliki gradovi (gradova s više od 35 000 stanovnika i gradova sjedišta županije kojih je ukupno 25) statistički značajnu manju izloženost za nemogućnost plaćanja od ostalih gradova. Javno dostupni podatci, primarno iz financijskih izvještaja promatranih gradova, predstavljaju podlogu za kreiranje parametara (primjerice parametar ukupni prihodi i primitci – *upp*), a stavljanjem u odnose različitih parametara kreirane su varijable koje su činile nezavisne varijable u korištenom modelu. Tako je kreirano i testirano 13 varijablā iz skupine *Financije i proračun*, 16 varijablā iz skupine *Likvidnost i dug* te četiri varijable iz skupine *Stanovništvo*. Zavisnu varijablu u korištenom modelu predstavljala je, u literaturi već definirana supstitucija za stečaj gradova koji u Republici Hrvatskoj zakonski nije moguć, varijabla koja je kreirana putem udjela dospjelih neplaćenih obveza u ukupnim obvezama iste godine mjerenima putem pozicije ukupnih rashoda i izdataka (*default_proxy*). Nakon provedene korelacijske analize, utvrđeno je da se hipoteze H1 do H3 ne odbacuju. Naime, u skupini *Financije i proračun*, dokazana je statistički značajna povezanost između varijabla udio prihoda od poreza u prihodima poslovanja (*ppor_pp*) i omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*) za zavisnom varijablom (*default_proxy*). Statistički značajna povezanost utvrđena je i za nekoliko drugih varijablā, ali s obzirom na očekivanu multikolinearnost odabrane su samo statistički najznačajnije varijable. U skupini *Likvidnost i dug* četiri su varijable statistički značajno povezane sa zavisnom varijablom. Radi se o varijablama udio obveza za kredite i zajmove i ukupnih obveza (*okz_uo*), omjeru potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*), omjeru kratkotrajne imovine i kratkoročnih obveza (*ki_ko*), te omjer gotovine i rashoda poslovanja (*got_rp*). U posljednjoj skupini, skupini *Stanovništvo* dokazana je statistički značajna povezanost samo varijable ocjena transparentnosti (*trans*). Važno je istaknuti da je za pet navedenih varijabli potvrđen očekivani smjer, dok je za dvije varijable utvrđen neočekivani smjer korelacije. Naime, smanjenje udjela prihoda od poreza u prihodima poslovanja (*ppor_pp*) negativno je povezano sa kretanjem zavisne varijable (*default_proxy*) odnosno smanjenjem udjela poreza te oslanjanje gradova na druge, vlastite izvore financiranja te pomoći, povećava se nemogućnost plaćanja obveza.

Negativna je korelacija utvrđena i za udio obveza za kredite i zajmove u ukupnim obvezama (*okz_uo*) odnosno smanjenje zaduženosti gradova rezultira porastom dospjelih nepodmirenih obveza. T-test nezavisnih uzoraka korišten je za dokazivanje četvrte hipoteze (H4) koja se temeljem dobivenih rezultata ne odbacuje odnosno veliki gradovi zaista imaju statistički značajno manju izloženost za nemogućnost plaćanja od ostalih gradova u Republici Hrvatskoj. Regresijska analiza panel-podataka korištena je za ispitivanje odnosa sedam izdvojenih nezavisnih varijablā sa zavisnom varijablom na način da se prate odnosi pojedine nezavisne varijable sa zavisnom kroz vrijeme. Iz skupine *Financije i proračun* ispitivanjem odnosa nezavisne varijable omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp*) i omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*) utvrđena je umjereno pozitivna povezanost. Nadalje, omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp*) predviđa kretanje omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*), ali u suprotnom smjeru. Drugim riječima, gradovi koji imaju visok omjer prenesenog manjka prihoda u prihodima poslovanja, u istoj godini imaju i visoku razinu omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (default_proxy), ali već u sljedećoj godini to rezultira nižim vrijednostima zavisne varijable (default_proxy). Druga varijabla iz navedene skupine (*ppor_pp*) nije postigla adekvatne indekse pogodnosti. U skupini *Likvidnost i dug* testiran je odnos četiri nezavisne varijable. Omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*) te je utvrđena niska, pozitivna povezanost koja je statistički značajna. Dodatno, utvrđena je i stabilnost varijable kroz vrijeme te će gradovi koji imaju visok omjer potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp*) u prethodnoj godini, imati visok omjer i u godini koja slijedi. Izdvojena nezavisna varijabla udio obveza za kredite i zajmove u ukupnim obvezama (*okz_uo*) i zavisne varijable nemogućnost plaćanja dospjelih obveza (*default_proxy*) nisko su negativno povezane. Slična negativna povezanost, ali puno nestabilnija kroz godine, utvrđena je i za varijablu omjera kratkotrajne imovine i kratkoročnih obveza (*ki_ko*). Za zadnju izdvojenu varijablu iz ove skupine, omjer gotovine i rashoda poslovanja (*got_rp*), utvrđena je vrlo slaba, gotovo zanemariva povezanost sa zavisnom varijablom (*default_proxy*).

U skupini *Stanovništvo* nije utvrđena statistički značajna povezanost u promatranom razdoblju između ocjene transparentnosti (*trans*) i omjera dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*). Kako bi dodatno ispitali dinamiku kretanja zavisne varijable nemogućnost plaćanja dospjelih obveza (*default_proxy*), korištena je analiza latentnog rasta krivulje.

Navedenom je analizom utvrđeno da su se gradovi značajno razlikovali s obzirom na omjer dospjelih nepodmirenih obveza u ukupnim rashodima i izdatcima (*default_proxy*), ali razlikovali su se i s obzirom na brzinu i smjer kretnja zavisne varijable. Gradovi su u promatranom razdoblju za 1,3 % prosječno smanjivali nemogućnost plaćanja obveza, a gradovi s nižim vrijednostima zavisne varijable, brže su istu smanjivali. Utvrđeno je i da prosječni omjer prenesenog manjka prihoda i prihoda poslovanja (*mpp_pp'*) predstavlja najbolji indikator budućih promjena od testiranih sedam varijablā. Trend smanjenja ili povećanja zavisne varijable ovisi još i o prosječnom omjeru potraživanja za prihode poslovanja i prihoda poslovanja (*potp_pp'*), zatim o prosječnom omjeru kratkotrajne imovine i kratkoročnih obveza (*ki_ko'*) te prosječnoj ocjeni transparentnosti (*trans'*). Sve prethodne analize i spoznaje opravdale su postavljanje višestrukog regresijskog modela s hijerarhijskim pristupom prema kojem je model s uključenim nezavisnim varijablama iz sve tri skupine pokazao statistički značajnu prediktivnu sposobnost. Važno je istaknut da je objašnjenost varijance takvog modela za početnu vrijednosti (*intercept*) 51 %. Nešto je kompleksnije predvidjeti brzinu i smjer kretanja zavisne varijable odnosno takav model za dinamiku kretanja nemogućnosti plaćanja obveza na vrijeme ima omogućava objašnjenost varijance na razini 28,3 %. Znanstveni doprinos, u teorijskom smislu, ove disertacije proizlazi iz znanstvenih spoznaja vezanih za financijsko upravljanje lokalnim jedinicama, zatim iz sistematiziranog pregleda znanstvenih dostignuća, te u prijedlogu modela predviđanja neplaćanja obveza gradova u Republici Hrvatskoj. U aplikativnom smislu, doprinos ove disertacije je u utvrđivanju povezanosti vremenskih serija podataka (višegodišnji podatci) s nemogućnošću plaćanja obveza gradova, ali i u identificiranju ključnih financijskih čimbenika i izradi modela. U konačni su stoga model uključene varijable *mpp_pp', potp_pp' i ki_ko'* odnosno varijable preneseni manjak prihoda, potraživanja za prihode poslovanja te omjer kratkotrajne imovine i kratkoročnih obveza imaju najveću snagu u objašnjenju varijacija zavisnih varijablā. Prediktivna sposobnost modela je značajna te izdvojene nezavisne varijable višestrukog regresijskog modela objašnjavaju 60,1 % varijacija zavisne varijable. Predstavljena jednadžba za izračun buduće vrijednosti prosječnog omjera dospjelih neplaćenih obveza u ukupnim rashodima i izdatcima (*default_proxy'*) omogućava jednostavno aplikativno rješenje koje može poslužiti kao sustav ranog upozorenja svim gradovima, ali i nadležnom ministarstvu te kreditorima. Naime, kako je svima u interesu plaćanje obveza gradova na vrijeme i u punom iznosu, nužno je pronaći način kako gradove potaknuti na smanjivanje dospjelih neplaćenih obveza, a predstavljeni model može poslužiti kao izvrstan alat za usporedbu gradova te upravljanje cjelokupnim sustavom gradova u Republici Hrvatskoj.

Literatura

Knjige i članci

1. Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The journal of finance. 23*(4), str. 589-609.

2. Altman, E. i Sabato, G. (2007). *Modelling credit risk for SMEs: Evidence from the US market*. Abacus. *43*(3), str. 332-357.

3. Anderson, R. (2007). *The credit scoring toolkit*. USA: Oxford University Press Inc.

4. Bach, S. (2014). *Financijska kriza i kreditni rejtinzi država*. Međunarodne studije. *14, ¾,* str. 10-28.

5. Bajo, A. (2004). *Zaduživanje lokalnih jedinica u Hrvatskoj: Mogućnosti i ograničenja*. Financijska teorija i praksa. 28 (2), str. 203-217.

6. Bajo, A. (2007). *Prijete li zaduživanja komunalnih poduzeća rastom duga lokalnih jedinica?* Newsletter br. 28. Institut za javne financije. str. 1-6

7. Bajo, A. (2008). Zašto je snižen kreditni rejting Zagrebačkom holdingu? *Aktualni osvrti. 1.* 5, str. 1-6.

8. Bajo, A. i Jurlina Alibegović, D. (2008). *Javne financije lokalnih jedinica vlasti*. Zagreb. Školska knjiga.

9. Bajo, A. i Penava, J. (2012). *Kreditne rejting agencije i kreditni rejting države.* Riznica. 1/2012, str. 45-57.

10. Bajo, A. i Primorac, M. (2009). *Zašto je potreban kreditni rejting lokalnih jedinica? Hrvatski javni sektor u aktualnim gospodarskim uvjetima*. Opatija. Hrvatska. 2. - 3. 9. 2009.

11. Bajo, A. i Primorac, M. (2010). Local government borrowing practice in Croatia. *Financial Theory and Practice.* 34 (4), str. 379-406.

12. Bajo, A. i Primorac, M. (2014). Dug i fiskalni rizici jedinica lokalne i područne (regionalne) samouprave. *Newsletter: povremeno glasilo Instituta za javne financije*. 16 (93), str. 1-8.

13. Bajo, A i Primorac, M. (2014). Nova raspodjela poreznih prihoda između središnje države i jedinica lokalne i područne (regionalne) samouprave. *Aktualni osvrt*. 72. Institut za javne financije

14. Bajo, A.; Primorac, M. i Andabaka Badurina, A. (2011). *Osnove upravljanja javnim dugom.* Zagreb. Institut za javne financije.

15. Bajo, A. i Stavljenić, B. (2017). *Uvjeti zaduživanja lokalnih jedinica tijekom financijske krize u Hrvatskoj*. *Financije na prekretnici: Imamo li snage za iskorak?* Blažić, H.; Dimitrić, M.; Pečarić, M. (ur.). Rijeka. Ekonomski fakultet Sveučilišta u Rijeci. str. 23-38.

16. Baletić, Z. (1995). *Ekonomski leksikon*. Zagreb. Leksikografski zavod Miroslav Krleža.

17. Belullo, A. (2011). *Uvod u ekonometriju.* Pula. Sveučilište Jurja Dobrile u Puli. Odjel za ekonomiju i turizam Dr. Mijo Mirković.

18. Benito, B. i Bastida, F. (2004). The determinants of the municipal debt policy in Spain. *Journal of Public Budgeting, Accounting & Financial Management*. 16 (4). str. 492-525.

19. Cantor, R. i Packer, F. (1995). The credit rating industry. *The Journal of Fixed income.* 5.3, str. 10-34.

20. Cantor, R. i Packer, F. (1996). D*eterminants and impact of sovereign credit ratings*. Economic policy review. 2 (2). str. 37-53.

21. Cohen, J. (1988). *Statistical Power Analysis for the Behavioral Sciences*. Hillsdale. NJ: Lawrence Erlbaum Associates.

22. Cohen, S.; Doumpos, M.; Neofytou, E. i Zopounidis, C. (2012). Assessing financial distress where bankruptcy is not an option: An alternative approach for local municipalities. *European Journal of Operational Research.* 218 (1). str. 270-279.

23. Crnković, L.; Martinović, J. i Mijoč, I. (2008). *Financijsko računovodstvo.* Osijek. Sveučilište J. J. Strossmayer u Osijeku. Ekonomski fakultet u Osijeku.

24. Denona Bogović, N.; Drezgić, S. i Čegar, S. (2017). *Evaluacija postojećeg i prijedlog novog modela za izračun indeksa te izračun novog indeksa razvijenosti jedinica lokalne i područne samouprave u Republici Hrvatskoj*. Cler d. o. o. Ekonomski fakultet Sveučilišta u Rijeci.

25. De Servigny, A. i Renault, O. (2004). *Measuring and managing credit risk*. USA. The McGraw-Hill Companies. Inc.

26. Družić, G. i Krtalić, S. (2006). Kakvu ulogu treba imati fiskalna politika u Republici Hrvatskoj? *Ekonomija - časopis za ekonomsku teoriju i politiku.* 13 (1). str. 67-84.

27. Državni zavod za statistiku (2011). *Statistički ljetopis Republike Hrvatske*. http://www.dzs.hr/Hrv_Eng/ljetopis/2011/SLJH2011.pdf (pristupljeno: 4. prosinca 2020.).

28. Elkhoury M. (2008). *Credit rating agencies and their impact on developing countries* United Nations Conference on Trade and Development. United Nations. Br. 186

29. Errais, E. (2019). What Drives Municipalities Default Risk? *International Journal of Economics and Finance*. 11(3). 49-57.

30. Faul, F.; Erdfelder, E.; Lang, A.G. & Buchner, A. (2007). *G*Power 3: A flexible statistical power analysis program for the social, behavioral, and biomedical sciences*. Behavior Research Methods. 39. 175-191.

31. Faul, F.; Erdfelder, E.; Buchner, A. & Lang, A.G. (2009). *Statistical power analyses using G*Power 3.1: Tests for correlation and regression analyses.* Behavior Research Methods. 41. 1149-1160.

32. Fitch Raiting Inc. (2016). *International Local and Regional Governments Rating Criteria-Outside the United States.* Master criteria. https://www.fitchratings.com/ research/international-public-finance/international-local-regional-governments-rating-criteria -outside-united-states-effective (pristupljeno: 2. svibnja 2020.).

33. Gaillard, N. (2009). The Determinants of Moody's Sub-Sovereign Ratings. *International Research Journal of Finance and Economics.* 31. str. 194-209.

34. Gorenc V. (ur.) (1997). *Rječnik trgovačkog prava*. Zagreb. Masmedia d. o. o.

35. Gorina, E.; Joffe, M. i Maher, C. (2018). *Using Fiscal Ratios to Predict Local Fiscal Distress.* Marcus working paper. Mercatus center. Str. 1-42.

36. *Government finance statistics manual 2014*. Washington D.C. International Monetary Fond. https://www.imf.org/external/Pubs/FT/GFS/Manual/2014/gfsfinal.pdf (pristupljeno: 28. studenoga 2020.).

37. Greene, W. H. (2007). *Econometric analysis 6th edition*. International edition. New Jersey. Prentice Hall.

38. Gregori, W. D. i Marattin, L. (2017). Determinants of fiscal distress in Italian municipalities. *Empirical Economics*. *56*(4). str. 1.269-1.281.

39. Hájek, P.; Hájková, V. (2009). Debt analysis of Czech municipalities. *Scientific Papers of the University of Pardubice*. 36-42.

40. Heywood, H. B. (1931). On finite sequences of real numera. *Proceedings of the Royal Society of London. Series A, Containing Papers of a Mathematical and Physical Character. 134*(824). str. 486–501.

41. Hohnjec, I.; Kocelj, A. i Jakir-Bajo, I. (2017). Novi model financiranja jedinica lokalne i područne (regionalne) samouprave. *Tim4pin magazin*. 9. str. 1-9.

42. Holian, M. J. i Joffe, M. D. (2013). *Assessing municipal bond default probabilities*. SAD. Sacramento. SSRN 2258801.

43. Horvat, J. i Mijoč, J. (2018). *Osnove statistike.* Zagreb. Naklada Ljevak.

44. Horvat, J. i Mijoč, J. (2019). *Istraživački SPaSS.* Osijek: Ekonomski fakultet u Osijeku i Naklada Ljevak.

45. Hu, L. T. i Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: 361 Conventional criteria versus new alternatives. *Structural Equation Modeling: A Multidisciplinary Journal, 6*(1). str. 1-55. doi:10.1080/10705519909540118

46. Jelčić, B. (1990). *Nauka o financijama i financijsko pravo*. Zagreb. Narodne novine.

47. Janda, K. i Moreira, D. (2016). Credit risk modelling: default probabilities for Portuguese municipalities. Munchen. MPRA. https://mpra.ub.uni-muenchen.de/74561/ (pristupljeno: 28. studenoga 2020.).

48. Jozić, Željko i dr. 2013. *Hrvatski pravopis.* Institut za hrvatski jezik i jezikoslovlje. Zrinski d. d. Čakovec.

49. Jurković, P. (2002). *Javne financije.* Zagreb. Masmedia d. o. o.

50. Jurlina Alibegović, D.; Kordej-De Villa, Ž. i Šagovac, M. (2018). Smart City Indicators: Can They Improve Governance in Croatian Large Cities? *EIZ-WP-1805*. Zagreb. Ekonomski institut Zagreb.

51. Kloha, P.; Weissert, C. S. i Kleine, R. (2005). *Developing and testing a composite model to predict local fiscal distress*. Public Administration Review. 65(3). str. 313-323.

52. Kolenikov, S. i Bollen, K. A. (2012). *Testing negative error variances: Is a Heywood case a symptom of misspecification?* Sociological Methods & Research. 41(1). str. 124-167.

53. Kregar, J. i suradnici (2011). *Decentralizacija*. Zagreb. Centar za demokraciju i pravo Miko Tripalo.

54. Krmpotić, D. (2015). *Zaduživanje lokalnih jedinica vlasti s posebnim osvrtom na Grad Osijek*. Osijek. Ekonomski fakultet u Osijeku. Poslijediplomski specijalistički studij Financije i Bankarstvo. Završni rad.

55. Kuhner, C. (2001). Financial rating agencies: Are they credible? Insights into the reporting incentives of rating agencies in times of enhanced systemic risk. *Schmalenbach Business Review*, *53*(1), str. 2-26.

56. Langohr, H. M. i Langohr, P. T. (2008). *The rating agencies and their credit ratings*.Chichester, England: Wiley finance series.

57. Leko, V. i Mates, N. (1993). *Rječnik bankarstva i financija*. Zagreb. Masmedia d. o. o.

58. Marković, B. i Dunković, B. (2009). Zaduživanje i financiranje lokalnog razvoja. Ekonomski vjesnik: časopis Ekonomskog fakulteta u Osijeku. God 22. br. 2. str. 354-363.

59. Marković, B. i Matić, B. (2006). *Problems of financing local and regional self-government*. GIS Applications and Development. Kereković, D. (ur). Zagreb. Hrvatski Informatički Zbor - GIS Forum. University of Silesia. str. 185-192.

60. Marković, B.; Matić, B. i Srb, V. (2003). Monetarne Financije. Osijek. Sveučilište J. J. Strossmayer u Osijeku. Ekonomski fakultet u Osijeku.

61. Marković, B. i Stojanović, S. (2007). *Financiranje jedinica lokalne samouprave na primjeru općine Šodolovci.* Financiranje razvoja i restrukturiranja gospodarstva. Marković, B.; Matić, B. i Novak, B. (ur.) (2007). Osijek. Sveučilište J. J. Strossmayer u Osijeku. Ekonomski fakultet u Osijeku. str.19-42.

62. Marušić, M.; Vranešević, T. (2001). *Istraživanje tržišta*. Zagreb. Adeco d. o. o.

63. Matić, B. (2011). *Monetarna ekonomija.* Osijek. Sveučilište J. J. Strossmayera u Osijeku. Ekonomski fakultet u Osijeku.

64. Mikić, M.; Orsag, S.; Pološki Vokić, N.; Sunajko, G. i Švaljek, S. (ur.) (2011). *Ekonomski leksikon*. Zagreb. Leksikografski zavod Miroslav Krleža i Masmedia d. o. o.

65. Mishkin, F. S. (2010). *Ekonomija novca, bankarstva i financijskih tržišta*. Zagreb. Mate d. o. o.

66. Moody's Investors Service (2018). Regional and Local Governments. Rating methodology. https://www.moodys.com/researchdocumentcontentpage.aspx?docid=PBC_1091595 (pristupljeno: 1. svibnja 2020.).

67. Moody's Investors Service (2018). *Annual Default Study: Corporate Default and Recovery Rates*. 1920 – 2017. https://www.moodys.com/researchdocumentcontentpage.aspx?docid= PBC_1112754 (pristupljeno: 28. studenoga 2020.).

68. Moody's Investor Service (2019). *Sub-Sovereign Default and Recovery Rates*. 1983-2018H1. https://www.moodys.com/researchdocumentcontentpage.aspx?docid=PBC_1110109 (pristupljeno: 26. studenoga 2020.).

69. Muhar, J. (2002). *Završni račun s analizom*. Zagreb. Poslovni zbornik d. o. o.

70. Musgrave, R. i Musgrave P. (1993). *Javne financije u teoriji i praksi.* Zagreb. Institut za javne financije.

71. Muthén, L. K. i Muthén, B. (2018). Mplus. *The comprehensive modelling program for applied researchers: user's guide*. 5.

72. Navarro-Galera, A.; Lara-Rubio, J.; Buendía-Carrillo, D. i Rayo-Canton, S. (2015). What can increase the default risk in local governments? *International Review of Administrative Sciences*. 83(2). str. 397-419.

73. Novak, B. (2005). *Financijska tržišta i institucije*. Osijek. Ekonomski fakultet u Osijeku.

74. Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of accounting research*. str. 109-131.

75. Ott, K.; Bronić, M. i Petrušić, M. (2013). Otvorenost proračuna hrvatskih županija, gradova i općina. *Newsletter br. 81*. Zagreb. Institut za javne financije.

76. Ott, K.; Bronić, M. i Petrušić, M. (2014). Otvorenost proračuna hrvatskih županija, gradova i općina 2013. - 2014. *Newsletter br. 87*. Zagreb. Institut za javne financije.

77. Ott, K.; Bronić, M. i Petrušić, M. (2015). Otvorenost proračuna hrvatskih županija, gradova i općina: studeni 2014. - ožujak 2015. *Newsletter br. 97*. Zagreb. Institut za javne financije.

78. Ott, K.; Bronić, M.; Petrušić, M. i Stanić, B. (2016). Otvorenost proračuna hrvatskih županija, gradova i općina: studeni 2015. - ožujak 2016. *Newsletter br. 107*. Zagreb. Institut za javne financije.

79. Ott, K.; Bronić, M.; Petrušić, M. i Stanić, B. (2017). Otvorenost proračuna hrvatskih županija, gradova i općina: studeni 2016. – ožujak 2017. *Newsletter br. 112*. Zagreb. Institut za javne financije.

80. Ott, K.; Bronić, M.; Petrušić, M. i Stanić, B. (2018). Otvorenost proračuna hrvatskih županija, gradova i općina: studeni 2017. - ožujak 2018. *Newsletter br. 115*. Zagreb. Institut za javne financije.

81. Palumbo, G.; Shick, R. i Zaporowski, M. (2006). Factors Affecting A Municipality's Bond Rating: An Empirical Study. *Journal of Business & Economics Research 4 (11)*. str. 37-42.

82. Pavković, A. (2012). Kreditne rejting agencije: od marginalnih igrača ka neizostavnim specijalistima financijskog posredovanja. *Računovodstvo i financije* br. 12. str. 131-137.

83. Pavković, A. i Vedriš, D. (2011). Redefiniranje uloge agencija za kreditni rejting u suvremenom financijskom sustavu. *Ekonomska misao i praksa: časopis Sveučilišta u Dubrovniku*. XX (1). str. 225-253.

84. Petz, B.; Kolesarić, V.; Ivanec, D.; Milas, G.; Podlesek, A. i Galić, Z. (2012). *Petzova statistika: osnovne statističke metode za nematematičare*. Naklada Slap.

85. Posedel, P. i Primorac, M. (2012). *Modelling local government unit credit risk in the Republic of Croatia*. Financial Theory and Practice 36 (4). str. 329-354.

86. Primorac, M. i Petrović, S. (2016). *Usporedna analiza zaduženosti lokalnih jedinica u zemljama Europske unije.* Stojanović, A. i Šimović, H. (ur.) *Aktualni problemi i izazovi razvoja financijskog sustava*. Zagreb. Ekonomski fakultet Zagreb. str. 251-271.

87. Primorac, M. i Poljak, K. (2018). *Fiskalni rizici poslovanja trgovačkih društava u vlasništvu velikih gradova.* D. Koški, D. Karačić i D. Sajter (ur.) *Financije: teorija i suvremena pitanja*. Sveučilište Josipa Jurja Strossmayera u Osijeku. Ekonomski fakultet u Osijeku. str. 41-74.

88. Rocco F. (ur.) (1993). *Rječnik marketinga*. Zagreb. Masmedia d. o. o.

89. Rogić Lugarić, T. (2012). *Financiranje velikih gradova*. Zagreb. Pravni fakultet sveučilišta u Zagrebu. Studijski centar za javnu upravu i javne financije.

90. Rosen, H. S. i Gayer, T. (2010). *Javne financije*. Zagreb. Institut za javne financije.

91. Sajter, D. (2009). Pregled određenih metoda i istraživanja poslovnih poteškoća odnosno predviđanja stečaja. *Ekonomska misao i praksa*. Sveučilište u Dubrovniku 2. str. 429-452.

92. Sajter, D. (2013). *Uvod u financijske izvedenice.* Osijek. Sveučilište J. J. Strossmayera u Osijeku. Ekonomski fakultet u Osijeku.

93. Sajter, D (2017). *Osnove upravljanja rizicima u financijskim institucijama*. Osijek. Ekonomski fakultet u Osijeku. Sveučilište J. J. Strossmayera u Osijeku.

94. Satorra, A. i Bentler, P. M. (2001). A scaled difference chi-square test statistic for moment structure analysis. *Psychometrika 66*(4). str. 507-514. doi:10.1007/BF02296192

95. Srb, V. i Matić, B. (2003). *Bankarsko poslovanje*. Osijek. Sveučilište J. J. Strossmayera u Osijeku. Ekonomski fakultet u Osijeku.

96. Steiger, J. H. (2000). Point estimation, hypothesis testing, and interval estimation using the RMSEA: Some comments and a reply to Hayduk and Glaser. *Structural Equation Modeling 7*(2). str. 149-162. doi:10.1207/S15328007SEM0702_1

97. *Standard & Poor's Financial Services* (2019). International Public Finance: Methodology For Rating Local And Regional Governments Outside Of The U. S. https://www.standardandpoors.com/en_US/web/guest/article/-/view/sourceId/10969943 (pristupljeno: 2. svibnja 2020.).

98. Stein, R. M. (2002). Benchmarking default prediction models: Pitfalls and remedies in model validation. *Moody's KMV.* New York. 20305.

99. Šarlija, N. (2002). *Modeli kreditnog rizika u ocjenjivanju kreditne sposobnosti malih poduzeća.* Doktorska disertacija. Sveučilište u Zagrebu. Ekonomski fakultet u Zagrebu.

100. Šimović, H.; Ćorić, T. i Deskar-Škrbić, M. (2014). Mogućnosti i ograničenja fiskalne politike u Hrvatskoj. *Ekonomski pregled* 65 (6). str. 541-575.

101. The World Bank (1999). Credit ratings and Bond Issuing at the Subnational Level. Training Manual, *International Bank for Reconstruction and Development.*

102. Trueck, S. i Rachev S. T. (2009). *Rating based modeling of credit risk,* Elsevier Inc.

103. Vasicek, O. A. (1984). Credit valuation. *White paper: KMV Corporation.*

104. Vukić, S. (2016). *Javne financije – teorija i praksa*. Ugljara. BiH: Grafolade&77x7.

105. Visković, J. i Katavić, M. (2017). Determinante kreditnog rejtinga zemalja Europske unije. *Financije na prekretnici: Imamo li snage za iskorak?* Blažić, H.; Dimitrić, M.; Pečarić, M. (ur.). Rijeka. Ekonomski fakultet Sveučilišta u Rijeci. str. 305-322.

106. Vlah Jerić, S i Primorac, M. (2017). Data mining for assessing the credit risk of local government units in Croatia. *Croatian operational research review 8.* str. 193-205.

107. White L. J. (2010). The Credit Rating Agencies. *Journal of Economic Perspectives 24 (2)*. 211-226.

Pravilnici, uredbe, registri i zakoni

108. UREDBA (EZ) br. 1060/2009 EUROPSKOG PARLAMENTA I VIJEĆA od 16. rujna 2009. o agencijama za kreditni rejting https://eur-lex.europa.eu/legal-content/ HR/TXT/ PDF/ ?uri=CELEX:32009R1060&from=HR (pristupljeno: 30. studenoga 2020.).

109. U. S. Securities and Exchange Commission (2003). *Report on the Role and Function of Credit Rating Agencies in the Operation of the Securities Markets*. https://www.sec.gov/ news/studies/credratingreport0103.pdf (pristupljeno: 30. studenoga 2020.).

110. The Technical Committee of the International Organisation of Securities Commissions (2003). *Report on the activities of credit rating agencies*. https://www.iosco.org/ library/ pubdocs/pdf/IOSCOPD153.pdf (pristupljeno: 30. studenoga 2020.).

111. Odluka o objavljivanju Hrvatskih standarda financijskog izvještavanja (Narodne novine br. 86/2015, 105/2020).

112. Pravilnik o financijskom izvještavanju u proračunskom računovodstvu (Narodne novine 3/2015, 93/2015, 135/2015, 2/2017, 28/2017, 112/2018 i 126/2019).

113. Pravilnik o postupku zaduživanja te davanja jamstava i suglasnosti jedinica lokalne i područne (regionalne) samouprave (Narodne novine 55/2009, 139/2010).

114. Pravilnik o proračunskim klasifikacijama (Narodne novine 26/2010, 120/2013 i 1/2020).

115. Pravilnik o proračunskom računovodstvu i računskom planu (Narodne novine 124/2014, 115/2015, 87/2016, 3/2018 i 126/2019).

116. Pravilnik o utvrđivanju proračunskih i izvanproračunskih korisnika državnog proračuna i proračunskih i izvanproračunskih korisnika proračuna jedinica lokalne i područne (regionalne) samouprave te o načinu vođenja Registra proračunskih i izvanproračunskih korisnika (Narodne novine 128/2009, 142/2014 i 23/2019).

117. Registar proračunskih i izvanproračunskih korisnika (Narodne novine 68/2015).

118. Stečajni zakon (Narodne novine 71/2015 i 104/2017).

119. Uredba o načinu izračuna iznosa pomoći izravnanja za decentralizirane funkcije jedinica lokalne i područne (regionalne) samouprave za 2020. godinu (Narodne novine 128/2019).

120. Uredba o indeksu razvijenosti (Narodne novine 131/2017).

121. Zakon o faktoringu (Narodne novine 94/2014, 85/2015, 41/2016).

122. Zakon o financijskom poslovanju i predstečajnoj nagodbi (Narodne novine 108/2012, 144/2012, 81/2013, 112/2013, 78/2015 i 71/2015).

123. Zakon o financiranju jedinica lokalne i područne (regionalne) samouprave (Narodne novine 127/2017, 138/2020).

124. Zakon o fiskalnoj odgovornosti (Narodne novine 111/2018, 41/2020).

125. Zakon o Gradu Zagrebu (Narodne novine 62/2001, 125/2008, 36/2009, 119/2014, 98/2019).

126. Zakon o izvršavanju Državnog proračuna Republike Hrvatske za 2020. godinu (Narodne novine 117/2019, 32/2020, 42/2020, 58/2020).

127. Zakon o javnoj nabavi (Narodne novine 120/2016).

128. Zakon o komunalnom gospodarstvu (Narodne novine 68/2018, 110/2018, 32/2020).

129. Zakon o koncesijama (Narodne novine 69/2017).

130. Zakon o kreditnim institucijama (Narodne novine 159/2013, 19/2015, 102/2015, 15/2018 i 70/2019).

131. Zakon o leasingu (Narodne novine 141/2013).

132. Zakon o lokalnim porezima (Narodne novine 115/2016, 101/2017).

133. Zakon o lokalnoj i područnoj (regionalnoj) samoupravi (Narodne novine 33/2001, 60/2001, 129/2005, 109/2007, 125/2008, 36/2009, 150/2011, 144/2012, 19/2013, 137/2015, 123/2017 i 98/2019).

134. Zakon o područjima posebne državne skrbi (Narodne novine 44/1996, 57/1996, 124/1997, 78/1999, 73/2000, 87/2000, 127/2000, 127/2000, 94/2001, 88/2002, 42/2005, 90/2005, 86/2008).

135. Zakon o porezu na dohodak (Narodne novine 115/2016, 106/2018, 121/2019, 32/2020).

136. Zakon o potvrđivanju Europske povelje o lokalnoj samoupravi (Narodne novine – Međunarodni ugovori 14/97, 4/08).

137. Zakon o porezu na promet nekretnina (Narodne novine 115/2016 i 106/2018).

138. Zakon o pravu na pristup informacijama (Narodne novine 25/13, 85/15).

139. Zakon o prodaji stanova na kojima postoji stanarsko pravo (Narodne novine 27/1991, 54/1991, 6/1992, 8/1992, 8/1992, 33/1992, 43/1992 - službeni pročišćeni tekst, 46/1992, 49/1992, 69/1992, 87/1992, 25/1993, 26/1993, 48/1993, 2/1994, 29/1994, 44/1994, 47/1994, 58/1995, 103/1995, 11/1996, 76/1996, 111/1996, 11/1997, 103/1997, 68/1998, 163/1998, 22/1999, 96/1999, 120/2000, 94/2001, 78/2002).

140. Zakon o proračunu (Narodne novine 87/2008, 136/2012, 15/2015).

141. Zakon o računovodstvu (Narodne novine 78/2015, 134/2015, 120/2016 i 116/2018).

142. Zakon o regionalnom razvoju Republike Hrvatske (Narodne novine 147/2014, 123/2017, 118/2018).

143. Zakon o tržištu kapitala (Narodne novine 65/2018).

144. Zakon o vatrogastvu (Narodne novine br. 106/1999, 117/2001, 36/2002, 96/2003, 174/2004, 38/2009, 80/2010, 125/2019).

Odluke, smjernice i zaključci

145. Odluka o gradskim porezima Grada Osijeka (Službeni glasnik Grada Osijeka 17A/2009, 7/2014, 14/2017, 17A/20).

146. Odluka o lokalnim porezima Grada Pula - Pola (Narodne novine br. 60/2017, 126/2017).

147. Odluka o komunalnom redu Grada Osijeka (Službeni glasnik Grada Osijeka 10/2019).

148. Odluka o razvrstavanju jedinica lokalne i područne (Narodne novine 132/2017).

149. Odluka Ustavnog suda (NN 26/07).

150. Statut Grada Osijeka (službeni glasnik Grada Osijeka br. 6/2001, 1A/2005 i 8/2005, 2/2009, 9/2009, 13/2009, 09/2013, 11/2013-pročišćeni tekst 12/2017, 2/2018, 2/2020 i 3/2020).

Mrežne (internetske) stranice

151. https://eur-lex.europa.eu/legal-content/HR/TXT/PDF/?uri=CELEX:32009R1060&from=HR (pristupljeno: 30. studenoga 2020.).

152. https://mfin.gov.hr/istaknute-teme/javni-dug/drzavna-jamstva/197 (pristupljeno: 17. svibnja 2020.).

153. https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/203 (pristupljeno: 1. studenoga 2020.).

154. https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/pr-ras-i-ras-funkc-za-razdoblje-2014-2018/208 (pristupljeno: 27. listopada 2020.).

155. https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/fiskalno-izravnanje/202 (pristupljeno: 11. studenoga 2020.).

156. https://mfin.gov.hr/istaknute-teme/medjunarodne-financijske-institucije/110 (pristupljeno: 4. prosinca 2020.).

157. https://mfin.gov.hr/pristup-informacijama/publikacije/smjernice-ekonomske-i-fiskalne-politike-zavod-za-makroekonomske-analize-i-planiranje/546?trazi=1&=&page=1 (pristupljeno: 22. lipnja 2020.).

158. https://mfin.gov.hr/proracun-86/86 (pristupljeno: 17. listopada 2020.).

159. https://mfin.gov.hr/proracun-86/drzavni-proracun-2020-godina/2981 (pristupljeno: 27. listopada 2020.).

160. https://mfin.gov.hr/proracun-86/drzavni-proracun-arhiva/610 (pristupljeno: 11. studenoga 2020.).

161. https://mfin.gov.hr/proracun-2020/povjerenstvo-za-fiskalnu-politiku/613 (pristupljeno: 22. lipnja 2020.).

162. https://razvoj.gov.hr/o-ministarstvu/djelokrug-1939/regionalni-razvoj/indeks-razvijenosti/vrijednosti-indeksa-razvijenosti-i-pokazatelja-za-izracun-indeksa-razvijenosti-2018/3740 (pristupljeno: 9. kolovoza 2020.).

163. https://statistika.hzz.hr/Statistika.aspx?tipIzvjestaja=1 (pristupljeno: 18. studenoga 2020.).

164. https://uprava.gov.hr/o-ministarstvu/ustrojstvo/uprava-za-politicki-sustav-drzavnu-upravu-te-lokalnu-i-podrucnu-regionalnu-samoupravu/lokalna-i-podrucna-regionalna-samouprava/popis-zupanija-gradova-i-opcina/846 (pristupljeno: 9. ožujka 2020.).

165. https://vlada.gov.hr/UserDocsImages/2016/Sjednice/2020/Travanj/227%20sjednica%20VRH/Novi%20direktorij/227%20%202%20Program%20konvergencije%20Republike%20Hrvatske%20za %202020. %20i %202021.%20godinu.pdf (pristupljeno: 8. studenoga 2020.).

166. https://zse.hr/hr/ cijene-vrijednosnih-papira/36?date=2015-01-02&model=ALL&type=M UNI-BOND (pristupljeno: 8. studenoga 2020.).

167. http://www.britannica.com/topic/public-sector (pristupljeno: 17. listopada 2019.).

168. http://www.dzs.hr/ (pristupljeno: 11. studenoga 2020.).

169. https://www.dzs.hr/Hrv_Eng/publication/2019/07-01-03_01_2019.htm (pristupljeno: 18. travnja 2020.).

170. https://www.dzs.hr/Hrv_Eng/publication/2020/07-01-01_01_2020.htm (pristupljeno: 13. studenoga 2020.).

171. https://www.dzs.hr/Hrv/censuses/census2011/results/censusmetod.htm (pristupljeno: 18. travnja 2020.).

172. https://www.dzs.hr/Hrv/censuses/census2011/results/censustabsxls.htm (pristupljeno: 18. travnja 2020.).

173. http://www.dsz.hr (Stanovništvo >> Procjene stanovništva >> Procjena stanovništva prema spolu, po gradovima/općinama, 31.12. (pristupljeno: 13. studenoga 2020.).

174. https://www.esma.europa.eu/sites/default/files/cra_regulation.pdf (22. lipnja 2020.).

175. https://www.esma.europa.eu/supervision/credit-rating-agencies/risk (pristupljeno: 1. studenoga 2020.).

176. https://www.fitchratings.com/research/international-public-finance/international-local-regional-governments-rating-criteria-outside-united-states-effective-from-18-april-2016-to-9-april-2019-18-04-2016 (pristupljeno: 2. svibnja 2020.).

177. https://www.fsb.org/wp-content/uploads/r_0804.pdf (pristupljeno: 10. svibnja 2020.).

178. https://www.hanfa.hr/leasing-i-faktoring/registri/faktoring-drustva/ (pristupljeno: 31. listopada 2020.).

179. https://www.hnb.hr/documents/20182/1131189/h-zemlje-clanice-eu-i-kandidati.pdf/dc91150c-cf59-4687-83f2-d08b2d3bfa00 (pristupljeno: 3. svibnja 2020.).

180. https://www.hnb.hr/documents/20182/1131189/h-standard-and-poors.pdf/b9ea141c-9f7e-426a-8108-647c7f4f9db2 (pristupljeno: 8. studenoga 2020.).

181. https://www.hnb.hr/statistika/glavni-makroekonomski-indikatori (pristupljeno: 17. ožujka 2020.).

182. https://www.hnb.hr/statistika/statisticki-podatci/opca-drzava/dug-opce-drzave (pristupljeno: 13. studenoga 2020.).

183. https://www.hnb.hr/temeljne-funkcije/medunarodni-odnosi/kreditni-rejting (pristupljeno: 8. studenoga 2020.).

184. https://www.hnb.hr/temeljne-funkcije/monetarna-politika/tecajna-lista/tecajna-lista (pristupljeno: 14. studenoga 2020.).

185. http://www.ijf.hr/transparentnost/?params_1=transparentnost (pristupljeno: 7. studenoga 2020.).

186. https://www.iosco.org/library/pubdocs/pdf/IOSCOPD153.pdf (pristupljeno: 30. studenoga 2020.).

187. https://www.mirovinsko.hr/hr/statistika/890 (pristupljeno: 18. studenoga 2020.).

188. https://www.moodys.com/credit-ratings/Zagreb-City-of-credit-rating-600049426 (pristupljeno: 8. studenoga 2020.).

189. https://www.moodys.com/researchdocumentcontentpage.aspx?docid=PBC_1110109 (pristupljeno: 26. studenoga 2020.).

190. https://www.moodys.com/researchdocumentcontentpage.aspx?docid=PBC_1112754 (pristupljeno: 28. studenoga 2020.).

191. https://www.moodys.com/researchdocumentcontentpage.aspx?docid=PBC_1091595 (pristupljeno: 1. svibnja 2020.).

192. http://www.mvep.hr/hr/vanjska-politika/multilateralni-odnosi0/multi-org-inicijative/vijece-europe/opcenito-o-vijecu-europe/ (pristupljeno: 19. listopada 2020.).

193. https://www.osijek.hr/gradska-uprava/gradski-uredi-odjeli-i-sluzbe/upravni-odjel-za-financije-i-nabavu/proracunski-dokumenti/ (pristupljeno: 14. studenoga 2020.).

194. https://www.porezna-uprava.hr/baza_znanja/Stranice/Nerezident.aspx (pristupljeno: 9. prosinca 2020.).

195. http://www.porezna-uprava.hr/HR_porezni_sustav/Stranice/prirez_porezu_na_dohodak (pristupljeno: 16. ožujka 2020.).

196. https://www.sabor.hr/hr/radna-tijela/odbori-i-povjerenstva/izvjesce-odbora-za-financije-i-drzavni-proracun-o-prijedlogu-515 (pristupljeno 19. listopada 2019.).

197. https://www.sec.gov/files/2019-annual-report-on-nrsros.pdf (pristupljeno: 6. studenoga 2020.).

198. https://www.sec.gov/news/studies/credratingreport0103.pdf (pristupljeno: 30. studenoga 2020.).

199. https://www.standardandpoors.com/en_US/web/guest/article/-/view/sourceId/10969943 (pristupljeno: 2. svibnja 2020.).

200. https://www.standardandpoors.com/en_US/web/guest/article//view/type/HTML/id/2185192#ContactInfo (pristupljeno: 19. srpnja 2020.).

201. www.standardandpoors.com/en_US/web/guest/ratings/entity/-/org-details/sectorCode/GOVS/entityId/336925 (pristupljeno: 8. studenoga 2020.).

202. http://www.vojko-obersnel.com/hr/proracunaj-me/2019 (pristupljeno: 17. listopada 2020.).

203. https://www.zgh.hr/o-nama/profil/13 (pristupljeno: 8. studenoga 2020.).

Popis tablica

Tablica 1. Pregled istraživača i veličine uzorka istraživanja 6
Tablica 2. Pregled velikih hrvatskih gradova s više od 35 000 stanovnika 17
Tablica 3. Veliki gradovi manji od 35 000 stanovnika koji su sjedišta županija..... 18
Tablica 4. Povijesni pregled vrsta dijeljenih poreznih prihoda lokalnih jedinica i..... 22
Tablica 5. Raspodjela poreza na dohodak..... 23
Tablica 6. Raspodjela sredstava fiskalnog izravnanja u periodu od 2018. do 2020. godine .. 25
Tablica 7. Povijesni pregled najvažnijih normativnih promjena lokalnih poreza..... 26
Tablica 8. Stope prireza u velikim gradovima (u postotcima)..... 27
Tablica 9. Porez na korištenje javnih površina za postavljanje ugostiteljskih terasa 30
Tablica 10. Prikaz skupine i podskupine ekonomske klasifikacije državnog proračuna u razdoblju od 2020. godine do 2022. godine (u 000 kuna) 44
Tablica 11. Primjer preraspodjele proračunskih sredstava proračunskog..... 46
Tablica 12. Izmjene proračuna temeljem izmjena financijskog plana (u 000 kuna) 47
Tablica 13. Pad proračunskih prihoda gradova temeljem zakonskih izmjena u..... 55
Tablica 14. Pregled municipalnih obveznica na Zagrebačkoj burzi 63
Tablica 15. Nominalni dnevni tečaj kune prema švicarskom franku od..... 69
Tablica 16. Povijesni pregled razvoja kreditnih rejting agencija..... 83
Tablica 17. Lista priznatih rejting organizacija (*NRSRO*) u SAD-u 86
Tablica 18. Pregled varijablā koje koristi agencija Standard and Poor's 89
Tablica 19. Pregled varijablā koje koristi agencija Moody's 91
Tablica 20. Pregled varijablā koje koristi agencija Fitch..... 94
Tablica 21. Pregled skala velikih kreditnih rejting agencija (ocjene dugoročnih obveza) 97
Tablica 22. Usporedba dodijeljenih rejtinga velikih rejting agencija zemljama članicama EU, ... 98
Tablica 23. Usporedni prikaz zemalja članica Europske Unije, Velike Britanije i zemalja kandidata za članstvo po rejting kategorijama prema agenciji S&P (rejting za dugoročno zaduživanje u stranoj valuti) 102
Tablica 24. *Scorecard* korišten pri ocjenjivanju poduzeća 107
Tablica 25. Primjer *scorecarda* korištenog od agencije Moody's za procjenu 108
Tablica 26. Pregled ukupnih prihoda općina, gradova i županija u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima) 116

Tablica 27. Pregled ukupnih prihoda velikih gradova u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima, uređenje prema silaznoj vrijednosti varijable u 2018. godini) 118
Tablica 28. Struktura prihoda poslovanja gradova u razdoblju od 2014. do 2018. godine .. 120
Tablica 29. Struktura poreznih prihoda gradova u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima) 121
Tablica 30. Pregled pomoći iz inozemstva općinama, gradovima i županijama u razdoblju od 2014. do 2018. godine (u 000 kuna i postotcima)..... 122
Tablica 31. Pregled ukupnih rashoda općina, gradova i županija u razdoblju..... 123
Tablica 32. Pregled rezultata tekuće godine velikih gradova u razdoblju od 2014. do 2018. godine (u 000 kuna, uređenje prema silaznoj vrijednosti manjka, pa viška u 2018. godini). 124
Tablica 33. Pregled prenesenog viška/manjka prihoda i primitaka raspoloživog/za pokriće u sljedećem razdoblju velikih gradova u razdoblju od 2014. do 2018. godine (u 000 kuna, uređenje prema silaznoj vrijednosti prenesenog manjka, pa prenesenog viška u 2018. godini) 126
Tablica 34. Pregled rashoda za kamate za primljene kredite i zajmove općina, gradova i... 127
Tablica 35. Vrijednost financijske imovine općina, gradova i županija u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima) 128
Tablica 36. Vrijednost ukupnih obveza općina, gradova i županija u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima) 130
Tablica 37. Vrijednost dospjelih obveza općina, gradova i županija u razdoblju od 2014. do 2018. godine (u 000 kuna i postotcima)..... 131
Tablica 38. Struktura dospjelih obveza gradova u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima) 132
Tablica 39. Pregled dospjelih obveza velikih gradova u razdoblju od 2014. do 2018. godine (u 000 kuna i postotcima, uređenje prema silaznoj vrijednosti varijable u 2018. godini) 133
Tablica 40. Visina duga temeljem izravnog zaduživanja općina, gradova i županija te duga opće države u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima)..... 135
Tablica 41. Obveze za kredite i zajmove velikih gradova u razdoblju od 2014. do 2018. godine (u 000 kuna i postotcima, uređenje prema silaznoj vrijednosti varijable u 2018. godini)..... 136
Tablica 42. Primitci od financijske imovine i zaduživanja općina, gradova i županija u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima)..... 137
Tablica 43. Izdatci za financijsku imovinu i otplate kredita općina, gradova i županija u razdoblju od 2014. do 2018. godine (u milijunima kuna i postotcima)..... 138

Tablica 44. Pregled kretanja ukupnog kreditnog duga gradova u razdoblju od 2014. do 2018. godine (u 000 kuna) 139
Tablica 45. Pregled kretanja ukupnog kreditnog duga velikih gradova u razdoblju od 2014. do 2018. godine (u 000 kuna, uređenje prema silaznoj vrijednosti varijable ukupno) 140
Tablica 46. Pregled kretanja procijenjenog broja stanovnika po općinama i gradovima u razdoblju od kraja 2013. do kraja 2018. godine (u 000) 142
Tablica 47. Pregled kretanja broja osiguranika mirovinskog osiguranja po općinama i gradovima u razdoblju od 2014. do 2018. godine (u 000) 143
Tablica 48. Pregled kretanja broja osiguranika mirovinskog osiguranja velikih gradova u razdoblju od 2014. do 2018. godine (prema silaznoj vrijednosti varijable u 2018. godini) .. 144
Tablica 49. Pregled kretanja broja nezaposlenih po općinama i gradovima u razdoblju od 2014. do 2018. godine (u 000) 145
Tablica 50. Pregled kretanja ocjena transparentnosti velikih gradova u razdoblju od 2015. do 2018. godine (uređenje prema silaznoj vrijednosti varijable u 2018. godini) 149
Tablica 51. Opis uzorka prema veličini gradova (veliki gradovi i broj stanovnika) 153
Tablica 52. Opis uzorka prema veličini gradova (mali gradovi i broj stanovnika) 154
Tablica 53. Pregled izdvojenih prihodovnih i rashodovnih parametara 156
Tablica 54. Pregled izdvojenih bilančnih parametara 158
Tablica 55. Pregled izdvojenih socioekonomskih parametara 159
Tablica 56. Financije i proračun – izdvojene varijable 162
Tablica 57. Likvidnost i dug – izdvojene varijable 164
Tablica 58. Stanovništvo – izdvojene varijable 166
Tablica 59. Deskriptivna analiza zavisne varijable 171
Tablica 60. Deskriptivna analiza 13 nezavisnih varijablā - skupina *Financije i proračun*... 173
Tablica 61. Deskriptivna analiza 16 nezavisnih varijablā - skupina *Likvidnost i dug* 175
Tablica 62. Deskriptivna analiza 4 nezavisne varijable - skupina *Stanovništvo* 176
Tablica 63. Deskriptivna analiza zavisne varijable po gradovima 177
Tablica 64. T-test nezavisnih uzoraka za zavisnu varijablu prema veličini gradova 181
Tablica 65. Korelacija - skupina *Financije i proračun* 182
Tablica 66. Korelacija - *Likvidnost i dug* 184
Tablica 67. Korelacija - *Stanovništvo* 186
Tablica 68. Deskriptivna analiza sedam odabranih varijablā 186
Tablica 69. Korelacija sedam izdvojenih varijablā - Varijable izdvojene za izgradnju modela predviđanja nemogućnosti plaćanja dospjelih obveza gradova 187

Tablica 70. Očekivani i stvarni smjer izdvojenih nezavisnih varijablā na zavisnu varijablu 188
Tablica 71. Deskriptivan opis varijable *default_proxy* 189
Tablica 72. Deskriptivan opis varijable *ppor_pp* 190
Tablica 73. Deskriptivan opis varijable *mpp_pp* 192
Tablica 74. Deskriptivan opis varijable *okz_uo* 193
Tablica 75. Deskriptivan opis varijable *potp_pp* 194
Tablica 76. Deskriptivan opis varijable *ki_ko* 195
Tablica 77. Deskriptivan opis varijable *got_rp* 196
Tablica 78. Deskriptivan opis varijable *trans* 198
Tablica 79. Pregled oznaka analiziranih varijablā u programu Mplus 199
Tablica 80. Prikaz početne vrijednosti i dinamike kretanja zavisne varijable za sve gradove (uređenje prema silaznoj vrijednosti brzine promjene i uzlaznoj vrijednosti početne vrijednosti) 209
Tablica 81. Deskriptivan opis nezavisnih varijablā 213
Tablica 82. Koeficijenti korelacije za početnu vrijednost i dinamike kretanja zavisne varijable u odnosu na nezavisne varijable 214
Tablica 83. Višestruki hijerarhijski regresijski modeli 216
Tablica 84. Odluke o hipotezama 220

Popis slika

Slika 1. Hrvatski javni sektor 12
Slika 2. Javni sektor i njegove osnovne komponente 13
Slika 3. Broj lokalnih jedinica vlasti 16
Slika 4. Bilančna podjela imovine lokalnih jedinica 35
Slika 5. Postupak donošenja proračuna lokalnih jedinica vlasti 45
Slika 6. Pregled kretanja javnog duga do 2021. godine 52
Slika 7. Dobavljački *faktoring* 64
Slika 8. Proces zaduživanja lokalne jedinice vlasti 75
Slika 9. Proces zaduživanja trgovačkih društava u vlasništvu lokalnih jedinica i 77
Slika 10. Prikaz odnosa jamstava i suglasnosti ustanovama i trgovačkim 78
Slika 11. Prikaz rezultata putanje modela (*mpp_pp* i *default_proxy*) 200
Slika 12. Prikaz rezultata putanje modela (*ppor_pp* i *default_proxy*) 201
Slika 13. Prikaz rezultata putanje modela (*okz_uo* i *default_proxy*) 202
Slika 14. Prikaz rezultata putanje modela (*potp_pp* i *default_proxy*) 202
Slika 15. Prikaz rezultata putanje modela (*ki_ko* i *default_proxy*) 203
Slika 16. Prikaz rezultata putanje modela (*got_rp* i *default_proxy*) 204
Slika 17. Prikaz rezultata putanje modela (*trans* i *default_proxy*) 205
Slika 18. Prikaz modela testiranog latentnom analizom rasta krivulje 206
Slika 19. Statistička značajnost prediktora u modeliranju *početne vrijednost i dinamike kretanja* 218
Slika 20. Statistička značajnost prediktora u konačnom modelu 219

Popis grafikona

Grafikon 1. Pregled rasta broja kreditnih rejtinga od 1970. do 2017. godine 84
Grafikon 2. Kretanje broja dodijeljenih kreditnih rejtinga lokalnih i regionalnih vlasti od strane agencije Moody's u razdoblju 1983. do 2017. godine 93
Grafikon 3. Kretanje rejtinga Republike Hrvatske i Grada Zagreba od 1997. do 2020. godine prema podatcima agencije S&P (dugoročno zaduživanje u stranoj valuti) 103
Grafikon 4. Kretanje rejtinga Grada Zagreba od 1999. do 2020. godine prema podatcima agencija Moody's i S&P (dugoročno zaduživanje u stranoj valuti)..... 104
Grafikon 5. Kretanje prosječne kumulirane stope *defaulta* izdavatelja po rejting kategorijama za lokalne jedinice u periodu 1983. do 30.6.2018. godine od strane agencije Moody's..... 111
Grafikon 6. Usporedba aritmetičkih sredina zavisnih podataka - *default_proxy* 190
Grafikon 7. Usporedba aritmetičkih sredina zavisnih podataka – *ppor_pp* 191
Grafikon 8. Usporedba aritmetičkih sredina zavisnih podataka – *mpp_pp* 192
Grafikon 9. Usporedba aritmetičkih sredina zavisnih podataka – *okz_uo* 193
Grafikon 10. Usporedba aritmetičkih sredina zavisnih podataka – *potp_pp*..... 195
Grafikon 11. Usporedba aritmetičkih sredina zavisnih podataka – *ki_ko* 196
Grafikon 12. Usporedba aritmetičkih sredina zavisnih podataka – *got_rp* 197
Grafikon 13. Usporedba aritmetičkih sredina zavisnih podataka - *trans* 198

Popis kratica

AOP	Automatska obrada podataka
BDP	Bruto domaći proizvod
bng	Broj nezaposlenih u gradu
bng_ubn	Omjer broja nezaposlenih u gradu u ukupnom broj nezaposlenih u RH
bsg	Procijenjeni broj stanovnika nekog grada
bsg_ubs	Omjer broja stanovnika grada u ukupnom broju stanovnika RH
bzg	Broj zaposlenih u gradu
bzg_ubz	Omjer broja zaposlenih u gradu u ukupnom broj zaposlenih u RH
dno	Dospjele nepodmirene obveze
got	Gotovina
got_rp	Omjer gotovine i rashoda poslovanja
gotd	Gotovina i depoziti
gotd_rp	Omjer gotovine i depozita i rashoda poslovanja
iz	Dug temeljem izravnog zaduživanja
iz_pp	Omjer duga temeljem izravnog zaduživanja i prihoda poslovanja
iz_ui	Omjer duga temeljem izravnog zaduživanja i ukupne imovine
iz_up	Omjer duga temeljem izravnog zaduživanja i ukupnih prihoda
izdat	Izdatci za financijsku imovinu i otplate zajmova
izdat_gotd	Omjer izdataka za financ. imovinu i otplate zajmova i gotovine i depozita
izdat_pp	Omjer izdataka za financijsku imovinu i otplate zajmova i prihoda poslovanja
izdatk	Izdatci za otplatu glavnice primljenih kredita i zajmova
izdatk_okz	Omjer izdataka za otplatu glavnice primljenih kredita i zajmova i obveza za kredite i zajmove
izdatk_pz	Omjer izdataka za otplatu glavnice primljenih kredita i zajmova i primitaka od zaduživanja
ki	Kratkotrajna imovina
ki_ko	Omjer kratkotrajne imovine i kratkoročnih obveza
ko	Kratkoročne obveze
mpp	Manjak prihoda i primitaka za pokriće u sljedećem razdoblju
mpp_pp	Omjer prenesenog manjka prihoda i prihoda poslovanja
nfi	Neto financijska imovina
nfi_pp	Omjer neto financijske imovine i prihoda poslovanja
nok	Neto obrtni kapital
nok_ur	Omjer neto obrtnog kapitala i ukupnih rashoda
nos	Neto operativni saldo
nos_pp	Udio neto operativnog salda u prihodima poslovanja
okz	Obveze za kredite i zajmove
okz_uo	Udio obveza za kredite i zajmove u ukupnim obvezama
pdkz	Primljeni dugoročni krediti, zajmovi i izdani vrijednosni papiri
pdkz_rni	Omjer primljenih dugoročnih kredita, zajmova i izdanih vrijednosnih papira i rashoda za nabavu nefinancijske imovine
pdoh	Prihodi od poreza i prireza na dohodak
pdoh_pp	Udio prihoda od poreza i prireza na dohodak u prihodima poslovanja
pom	Pomoć iz inozemstva i od subjekata unutar općeg proračuna

pom_pp	Udio pomoći u prihodima poslovanja
pomEU	Pomoć od inozemnih vlada, međunarodnih organizacija te institucija i tijela EU
pomEU_pp	Udio pomoći od međunarodnih organizacija, inozemnih vlada te institucija i tijela EU u prihodima poslovanja
potp	Potraživanja za prihode poslovanja
potp_pp	Omjer potraživanja za prihode poslovanja i prihoda poslovanja
pp	Prihodi poslovanja
pp_up	Udio prihoda poslovanja u ukupnim prihodima
ppor	Prihodi od poreza
ppor_pp	Udio prihoda od poreza u prihodima poslovanja
ppor_up	Udio prihoda od poreza u ukupnim prihodima
pz	Primitci od zaduživanja
rni	Rashodi za nabavu nefinancijske imovine
rni_upp	Omjer rashoda za nabavu nefinancijske imovine i ukupnih prihoda i primitaka
rp	Rashod poslovanja
rp_ur	Udio rashoda poslovanja u ukupnim rashodima
S&P	Standard & Poor's
trans	Ocjena transparentnosti
trk	Troškovi kamata
trk_uri	Omjer troškova kamata i ukupnih rashoda i izdataka
ubn	Ukupan broj nezaposlenih u RH
ubs	Procijenjeni ukupni broj stanovnika RH
ubz	Ukupan broj zaposlenih u RH
ui	Ukupna imovina
uo	Ukupne obveze
up	Ukupni prihod
upp	Ukupni prihodi i primitci
upr	Višak raspoloživ ili manjak za pokriće u sljedećem razdoblju
upr_up	Omjer ukupnog prenesenog rezultata i ukupnih prihoda
ur	Ukupni rashod
ur_up	Omjer ukupnih rashoda i ukupnih prihoda
uri	Ukupni rashodi i izdatci
vp	Vlastiti prihod
vp_pp	Udio vlastitih prihoda u prihodima poslovanja

Prilog 1. Dospjele nepodmirene obveze gradova od 2014. do 2018. godine (u 000 kuna)

Grad	2014.	2015.	2016.	2017.	2018.
DUGO SELO	1.091	1.111	697	158	717
IVANIĆ-GRAD	2.734	1.658	1.356	911	496
JASTREBARSKO	229	181	19	19	21
SAMOBOR	2.830	3.985	3.943	3.494	1.686
SVETA NEDJELJA	229	170	82	53	85
SVETI IVAN ZELINA	0	0	0	1.533	0
VELIKA GORICA	1.508	4.038	273	76	490
VRBOVEC	240	384	36	516	13
ZAPREŠIĆ	4.495	839	877	936	0
DONJA STUBICA	635	251	552	586	141
KLANJEC	579	449	369	832	348
KRAPINA	0	0	0	0	0
OROSLAVJE	708	455	194	527	1.020
PREGRADA	645	590	637	198	205
ZABOK	0	0	0	0	0
ZLATAR	2.708	1.575	1.232	1.128	655
GLINA	477	0	79	1	1
HRVATSKA KOSTAJNICA	2.161	2.659	2.922	3.250	2.322
KUTINA	1.946	2.509	2.071	4.594	5.108
NOVSKA	151	153	67	498	658
PETRINJA	567	6.560	0	15.174	9.790
POPOVAČA	0	5	849	3.325	832
SISAK	2.370	2.287	3.699	5.863	2.574
DUGA RESA	1.087	3	4	459	121
KARLOVAC	594	243	261	250	286
OGULIN	21	55	55	55	143
OZALJ	0	0	0	0	0
SLUNJ	0	0	0	0	0
IVANEC	13	3	0	118	0
LEPOGLAVA	102	1.228	685	1.097	276
LUDBREG	2.667	3.754	2.709	4.551	1.305
NOVI MAROF	1.924	2.108	875	1.357	714
VARAŽDIN	38.777	39.853	22.173	20.725	25.214
VARAŽDINSKE TOPLICE	2	236	41	7	15
ĐURĐEVAC	399	72	91	342	235
KOPRIVNICA	5.509	6.599	13.070	14.780	4.523
KRIŽEVCI	8.046	8.509	4.676	866	391
BJELOVAR	5.263	1.301	44	227	218
ČAZMA	1.423	1.314	3.037	2.746	2.962
DARUVAR	3.219	2.497	1.678	349	255
GAREŠNICA	4.424	666	2.008	1.741	15

GRUBIŠNO POLJE	2.226	1.889	1.495	1.040	2.314
BAKAR	214	0	0	0	11.647
CRES	29	0	306	431	1.040
CRIKVENICA	61	61	61	61	61
ČABAR	4.207	3.188	6.648	5.901	7.000
DELNICE	7.274	5.126	3.779	4.976	4.974
KASTAV	626	51	187	678	140
KRALJEVICA	945	1.036	0	0	0
KRK	18.038	683	635	65	262
MALI LOŠINJ	13.490	6.897	9.685	7.094	2.735
NOVI VINODOLSKI	8.114	8.160	9.357	7.882	4.639
OPATIJA	46.070	0	150	0	6.207
RAB	11.259	7.188	4.238	5.009	8.951
RIJEKA	144.588	172.615	174.743	192.856	128.064
VRBOVSKO	0	0	0	0	0
GOSPIĆ	8	776	2.089	4.848	5.368
NOVALJA	1.373	1.025	605	1.491	896
OTOČAC	11.709	8.526	7.584	7.324	7.572
SENJ	2.278	946	2.794	3.771	2.944
ORAHOVICA	8.078	8.075	8.075	8.199	357
SLATINA	1.961	2.437	585	2.551	572
VIROVITICA	292	4	56	805	760
KUTJEVO	2.429	2.085	640	857	94
LIPIK	992	1.150	2.468	4.517	3.222
PAKRAC	3.707	3.996	772	690	0
PLETERNICA	8.627	7.179	3.470	3.374	1.709
POŽEGA	1.170	1.598	479	19	306
NOVA GRADIŠKA	768	427	63	121	144
SLAVONSKI BROD	10.982	11.972	7.334	181	529
BENKOVAC	4.978	4.165	2.427	3.591	1.108
BIOGRAD NA MORU	15.644	14.467	12.780	10.582	12.793
NIN	901	376	99	328	551
OBROVAC	6.263	3.010	1.686	2.112	1.334
PAG	2.414	1.561	3.584	4.623	2.584
ZADAR	50.526	55.318	50.268	51.186	44.509
BELI MANASTIR	1.155	700	76	70	2.584
BELIŠĆE	2.827	1.406	2.040	2.084	1.542
DONJI MIHOLJAC	3.828	4.963	7.112	6.921	3.085
ĐAKOVO	4.763	2.005	3.032	74	13
NAŠICE	424	416	113	0	313
OSIJEK	3.215	2.914	1.186	156	1.021
VALPOVO	3.807	3.947	3.564	6.068	7.070
DRNIŠ	2.265	3.551	1.828	3.386	1.402
KNIN	10.755	12.527	7.108	4.816	3.952

SKRADIN	588	921	491	345	380
ŠIBENIK	19.610	30.559	35.923	44.583	24.182
VODICE	3.245	2.651	3.902	4.044	4.901
ILOK	5.280	4.863	3.738	3.829	2.189
OTOK.	4.446	6.064	4.018	7.038	8.093
VINKOVCI	0	5.755	5.215	7.704	12.376
VUKOVAR	4.704	6.935	1.805	373	49
ŽUPANJA	1.705	705	1.907	1.114	564
HVAR	34	1.601	635	664	386
IMOTSKI	3.238	3.421	3.454	2.179	635
KAŠTELA	8.346	5.077	906	1.269	1.132
KOMIŽA	796	1.576	175	149	262
MAKARSKA	3.972	3.465	3.811	4.910	4.411
OMIŠ	20.979	24.247	19.704	17.067	15.550
SINJ	3.303	1.682	319	525	672
SOLIN	9.090	5.157	5.333	3.316	1.917
SPLIT	26.489	27.957	17.702	20.259	23.585
STARI GRAD	1.545	884	492	581	445
SUPETAR	8.557	9.084	12.990	9.125	13.808
TRILJ	767	675	854	3.998	440
TROGIR	22.328	21.713	19.231	17.505	3.993
VIS	1.513	1.703	1.659	2.076	1.036
VRGORAC	2.958	2.693	2.715	2.912	6.060
VRLIKA	1.850	1.440	945	1.345	3.587
BUJE	342	8	8	38	174
BUZET	353	106	273	280	285
LABIN	181	228	352	2.424	327
NOVIGRAD	62	246	132	507	778
PAZIN	6.087	4.071	4.279	5.387	4.134
POREČ	693	50	301	392	172
PULA	4.597	3.598	2.396	5.366	4.802
ROVINJ	0	0	0	0	0
UMAG	1.348	874	520	433	803
VODNJAN	6.673	5.486	6.387	5.704	5.570
DUBROVNIK	0	0	0	0	0
KORČULA	2.224	3.140	2.304	1.277	682
METKOVIĆ	5.810	3.052	2.171	3.295	4.604
OPUZEN	696	914	690	980	1.162
PLOČE	10.545	7.489	6.825	6.763	7.257
ČAKOVEC	5.095	11.259	11.568	6.995	11.380
MURSKO SREDIŠĆE	756	329	609	603	558
PRELOG	954	1.555	763	5.934	7.571
ZAGREB	47.674	15.555	14.669	80.124	153.081

Prilog 2. Ukupni rashodi i izdatci gradova od 2014. do 2018. godine (u 000 kuna)

Grad	2014.	2015.	2016.	2017.	2018.
DUGO SELO	42.356	39.759	41.415	44.834	51.797
IVANIĆ-GRAD	49.801	47.421	59.394	58.389	67.968
JASTREBARSKO	58.059	48.473	49.734	51.032	51.034
SAMOBOR	163.831	214.074	230.707	183.225	194.839
SVETA NEDJELJA	76.295	79.238	76.416	77.533	97.822
SVETI IVAN ZELINA	33.775	29.136	34.335	31.691	44.900
VELIKA GORICA	250.609	307.113	236.947	355.009	311.743
VRBOVEC	36.246	32.729	32.944	43.565	43.389
ZAPREŠIĆ	117.648	121.240	138.691	151.992	145.859
DONJA STUBICA	16.584	9.741	13.886	14.424	15.296
KLANJEC	6.067	7.258	5.764	6.309	12.950
KRAPINA	30.273	31.618	33.711	36.633	36.131
OROSLAVJE	12.219	12.742	13.105	13.766	16.665
PREGRADA	13.648	11.492	13.811	11.550	18.218
ZABOK	35.668	37.447	41.827	35.992	38.937
ZLATAR	8.768	8.423	11.926	15.253	15.644
GLINA	20.510	24.445	32.929	27.294	32.044
HRVATSKA KOSTAJNICA	5.896	10.979	9.973	6.815	7.111
KUTINA	76.066	70.865	71.246	77.582	91.440
NOVSKA	38.306	43.010	38.284	45.626	56.319
PETRINJA	73.793	75.538	74.544	71.544	112.082
POPOVAČA	37.596	33.429	30.930	34.352	44.731
SISAK	172.430	169.111	196.207	219.945	181.760
DUGA RESA	25.012	20.601	20.687	22.587	22.768
KARLOVAC	229.653	208.052	232.668	220.281	207.864
OGULIN	37.782	38.768	35.277	34.035	61.497
OZALJ	15.686	17.163	22.133	24.573	26.177
SLUNJ	18.384	14.062	16.223	14.419	26.303
IVANEC	22.713	25.861	25.836	25.855	38.013
LEPOGLAVA	20.501	19.753	11.850	13.913	17.938
LUDBREG	21.424	27.081	56.233	27.856	35.335
NOVI MAROF	17.788	17.379	17.780	22.195	26.993
VARAŽDIN	230.855	208.752	209.584	200.246	250.229
VARAŽDINSKE TOPLICE	12.188	12.338	12.721	8.932	17.022
ĐURĐEVAC	25.437	32.362	39.613	40.220	56.255
KOPRIVNICA	147.120	138.396	133.082	147.136	146.122
KRIŽEVCI	64.567	60.798	80.719	45.526	62.093
BJELOVAR	114.185	113.194	114.439	117.013	132.374
ČAZMA	15.773	17.250	27.594	23.978	27.772
DARUVAR	28.277	25.928	25.480	26.084	42.099

GAREŠNICA	17.805	21.938	24.456	25.014	38.433
GRUBIŠNO POLJE	21.535	20.829	23.548	20.279	28.454
BAKAR	47.585	49.108	48.341	54.951	61.277
CRES	23.638	28.213	27.731	28.444	15.633
CRIKVENICA	66.590	62.070	78.214	103.874	27.323
ČABAR	15.625	16.378	11.332	11.746	88.074
DELNICE	33.118	33.813	24.918	24.191	36.608
KASTAV	40.839	38.481	57.152	46.249	49.012
KRALJEVICA	14.939	15.348	19.212	16.519	17.491
KRK	65.373	63.117	53.557	55.958	60.929
MALI LOŠINJ	70.248	76.370	76.193	65.265	72.837
NOVI VINODOLSKI	27.772	28.250	31.686	35.257	42.173
OPATIJA	120.228	105.649	172.911	132.826	186.173
RAB	42.185	31.904	34.124	37.970	58.786
RIJEKA	707.826	696.252	690.843	692.212	734.840
VRBOVSKO	18.188	15.498	15.918	15.535	21.529
GOSPIĆ	67.938	60.378	60.321	56.312	61.896
NOVALJA	41.627	42.508	47.113	44.429	45.333
OTOČAC	20.436	22.708	26.521	27.466	25.389
SENJ	28.836	30.925	33.690	40.323	57.112
ORAHOVICA	15.301	15.184	20.413	22.512	22.081
SLATINA	31.424	31.689	29.947	33.432	38.700
VIROVITICA	75.160	95.107	71.165	72.658	157.931
KUTJEVO	9.795	14.551	17.659	10.617	14.306
LIPIK	41.756	21.726	20.664	25.048	30.726
PAKRAC	50.069	20.470	19.005	28.367	29.134
PLETERNICA	26.321	25.049	22.555	26.673	48.066
POŽEGA	70.982	63.609	85.400	82.457	96.378
NOVA GRADIŠKA	30.850	46.358	45.818	49.670	52.452
SLAVONSKI BROD	126.573	128.832	149.454	155.513	159.667
BENKOVAC	24.220	24.097	23.698	28.535	41.781
BIOGRAD NA MORU	39.944	34.651	39.345	44.273	53.240
NIN	18.739	17.330	20.124	22.621	35.974
OBROVAC	18.368	21.597	18.457	24.114	32.297
PAG	17.669	24.147	41.325	23.528	52.294
ZADAR	362.582	344.768	391.337	365.879	362.972
BELI MANASTIR	34.856	31.878	36.308	36.125	47.973
BELIŠĆE	57.227	40.328	42.647	40.158	54.757
DONJI MIHOLJAC	20.032	17.348	17.181	16.903	68.605
ĐAKOVO	39.311	40.566	53.441	59.336	27.168
NAŠICE	40.943	46.953	42.241	36.446	48.341
OSIJEK	417.105	355.074	351.676	400.137	436.898
VALPOVO	20.922	20.202	23.551	29.631	40.561
DRNIŠ	28.208	27.681	26.823	23.204	25.770

KNIN	34.599	39.286	35.088	32.364	65.948
SKRADIN	15.299	11.974	10.332	9.770	12.304
ŠIBENIK	204.641	178.290	169.377	184.471	186.614
VODICE	41.893	50.293	48.312	58.645	52.861
ILOK	18.911	15.032	17.648	17.646	22.493
OTOK.	11.482	15.274	13.961	18.093	28.369
VINKOVCI	106.939	87.514	119.111	94.529	117.233
VUKOVAR	96.225	124.479	146.976	131.647	178.053
ŽUPANJA	31.415	31.175	28.916	31.119	47.728
HVAR	37.101	36.551	40.087	41.845	50.264
IMOTSKI	29.246	26.464	27.498	25.406	31.493
KAŠTELA	101.970	105.683	102.694	113.226	117.684
KOMIŽA	6.241	9.995	5.285	6.305	8.581
MAKARSKA	67.807	65.908	72.654	88.609	94.184
OMIŠ	55.956	51.393	77.817	74.906	66.267
SINJ	52.373	49.329	47.017	48.072	65.781
SOLIN	87.529	92.217	91.581	93.798	93.961
SPLIT	761.316	709.952	773.137	737.500	836.588
STARI GRAD	18.857	12.734	16.099	14.106	27.724
SUPETAR	27.686	30.495	27.224	25.385	29.649
TRILJ	17.792	26.033	22.826	26.628	26.298
TROGIR	50.624	48.018	57.133	60.564	74.620
VIS	18.839	14.033	15.876	16.678	13.929
VRGORAC	18.855	14.413	15.200	16.737	30.807
VRLIKA	23.103	15.515	10.607	10.637	15.650
BUJE	22.800	25.578	27.619	24.263	25.584
BUZET	35.928	41.004	34.451	30.934	32.598
LABIN	65.981	62.518	67.044	90.665	70.416
NOVIGRAD	37.864	40.096	46.461	41.572	46.777
PAZIN	74.000	48.736	50.780	53.882	56.962
POREČ	123.010	137.183	139.701	182.104	215.101
PULA	286.803	270.489	289.074	337.467	313.781
ROVINJ	119.000	132.410	118.146	123.302	122.867
UMAG	113.240	108.402	137.746	131.668	118.076
VODNJAN	42.682	39.557	39.946	46.591	39.912
DUBROVNIK	397.682	371.197	410.158	378.789	503.096
KORČULA	35.206	20.644	23.970	24.554	28.111
METKOVIĆ	26.800	28.092	26.114	25.741	42.976
OPUZEN	9.557	10.452	7.491	8.050	26.440
PLOČE	27.619	22.365	24.235	29.115	40.005
ČAKOVEC	102.590	106.410	125.318	114.248	119.366
MURSKO SREDIŠĆE	10.066	12.625	23.625	19.794	21.624
PRELOG	23.597	24.744	24.622	32.570	39.944
ZAGREB	7.855.310	6.371.242	6.934.104	7.325.310	7.897.065
UKUPNO	16.880.918	15.167.751	16.281.725	16.821.171	18.648.693

Prilog 3. Nemogućnost plaćanja dospjelih obveza (*default_proxy*) od 2014. do 2018. godine (uređenje prema uzlaznoj vrijednosti varijable u 2018. godini)

Grad	2014.	2015.	2016.	2017.	2018.
SVETI IVAN ZELINA	0,00000	0,00000	0,00000	0,04837	0,00000
ZAPREŠIĆ	0,03820	0,00692	0,00632	0,00616	0,00000
KRAPINA	0,00000	0,00000	0,00000	0,00000	0,00000
ZABOK	0,00000	0,00000	0,00000	0,00000	0,00000
OZALJ	0,00000	0,00000	0,00000	0,00000	0,00000
SLUNJ	0,00000	0,00000	0,00000	0,00000	0,00000
IVANEC	0,00058	0,00010	0,00000	0,00457	0,00000
KRALJEVICA	0,06326	0,06753	0,00000	0,00000	0,00000
VRBOVSKO	0,00000	0,00000	0,00000	0,00000	0,00000
PAKRAC	0,07404	0,19524	0,04061	0,02431	0,00000
ROVINJ	0,00000	0,00000	0,00000	0,00000	0,00000
DUBROVNIK	0,00000	0,00000	0,00000	0,00000	0,00000
GLINA	0,02327	0,00000	0,00241	0,00004	0,00003
VUKOVAR	0,04889	0,05571	0,01228	0,00283	0,00028
VRBOVEC	0,00661	0,01174	0,00108	0,01184	0,00031
GAREŠNICA	0,24849	0,03038	0,08209	0,06961	0,00040
JASTREBARSKO	0,00394	0,00373	0,00038	0,00037	0,00042
ĐAKOVO	0,12117	0,04942	0,05674	0,00124	0,00049
POREČ	0,00564	0,00037	0,00215	0,00215	0,00080
SVETA NEDJELJA	0,00300	0,00214	0,00107	0,00068	0,00087
VARAŽDINSKE TOPLICE	0,00012	0,01915	0,00324	0,00082	0,00089
KARLOVAC	0,00259	0,00117	0,00112	0,00113	0,00137
VELIKA GORICA	0,00602	0,01315	0,00115	0,00021	0,00157
BJELOVAR	0,04609	0,01150	0,00038	0,00194	0,00165
CRIKVENICA	0,00092	0,00098	0,00078	0,00059	0,00224
OGULIN	0,00054	0,00141	0,00156	0,00162	0,00232
OSIJEK	0,00771	0,00821	0,00337	0,00039	0,00234
NOVA GRADIŠKA	0,02488	0,00920	0,00138	0,00245	0,00274
KASTAV	0,01532	0,00131	0,00327	0,01466	0,00286
POŽEGA	0,01648	0,02512	0,00561	0,00023	0,00317
SLAVONSKI BROD	0,08676	0,09293	0,04907	0,00116	0,00331
ĐURĐEVAC	0,01569	0,00222	0,00230	0,00851	0,00417
KRK	0,27593	0,01083	0,01187	0,00116	0,00430
LABIN	0,00275	0,00364	0,00524	0,02674	0,00465
VIROVITICA	0,00389	0,00005	0,00079	0,01108	0,00481
DUGA RESA	0,04347	0,00016	0,00021	0,02034	0,00531
DARUVAR	0,11382	0,09629	0,06584	0,01338	0,00607
KRIŽEVCI	0,12461	0,13996	0,05793	0,01902	0,00630
NAŠICE	0,01035	0,00887	0,00268	0,00000	0,00647

KUTJEVO	0,24801	0,14328	0,03624	0,08072	0,00654
BUJE	0,01501	0,00030	0,00027	0,00155	0,00679
UMAG	0,01190	0,00806	0,00377	0,00329	0,00680
IVANIĆ-GRAD	0,05490	0,03496	0,02282	0,01561	0,00729
HVAR	0,00093	0,04380	0,01585	0,01588	0,00769
SAMOBOR	0,01727	0,01862	0,01709	0,01907	0,00865
BUZET	0,00984	0,00259	0,00793	0,00904	0,00874
DONJA STUBICA	0,03827	0,02579	0,03974	0,04061	0,00924
KAŠTELA	0,08185	0,04804	0,00882	0,01121	0,00962
SINJ	0,06307	0,03410	0,00679	0,01092	0,01022
PREGRADA	0,04724	0,05130	0,04614	0,01715	0,01124
NOVSKA	0,00393	0,00356	0,00176	0,01091	0,01169
ŽUPANJA	0,05429	0,02261	0,06596	0,03580	0,01182
DUGO SELO	0,02576	0,02795	0,01684	0,00353	0,01384
SISAK	0,01375	0,01353	0,01885	0,02666	0,01416
SLATINA	0,06240	0,07691	0,01953	0,07629	0,01478
PULA	0,01603	0,01330	0,00829	0,01590	0,01531
NIN	0,04807	0,02171	0,00492	0,01450	0,01532
LEPOGLAVA	0,00499	0,06219	0,05783	0,07888	0,01541
STARI GRAD	0,08195	0,06939	0,03056	0,04119	0,01604
ORAHOVICA	0,52792	0,53182	0,39556	0,36422	0,01616
NOVIGRAD	0,00163	0,00613	0,00284	0,01218	0,01664
TRILJ	0,04310	0,02592	0,03739	0,15013	0,01672
POPOVAČA	0,00000	0,00016	0,02745	0,09680	0,01859
ZAGREB	0,00607	0,00244	0,00212	0,01094	0,01938
NOVALJA	0,03299	0,02411	0,01285	0,03355	0,01977
IMOTSKI	0,11072	0,12929	0,12560	0,08576	0,02017
SOLIN	0,10386	0,05592	0,05823	0,03535	0,02040
KORČULA	0,06318	0,15210	0,09612	0,05202	0,02427
MURSKO SREDIŠĆE	0,07515	0,02602	0,02580	0,03045	0,02580
NOVI MAROF	0,10818	0,12130	0,04923	0,06113	0,02645
BENKOVAC	0,20554	0,17282	0,10243	0,12586	0,02653
KLANJEC	0,09542	0,06187	0,06407	0,13180	0,02691
BELIŠĆE	0,04940	0,03486	0,04783	0,05190	0,02816
SPLIT	0,03479	0,03938	0,02290	0,02747	0,02819
KOMIŽA	0,12761	0,15766	0,03310	0,02370	0,03048
SKRADIN	0,03843	0,07696	0,04752	0,03535	0,03088
KOPRIVNICA	0,03745	0,04768	0,09821	0,10045	0,03096
OPATIJA	0,38319	0,00000	0,00087	0,00000	0,03334
PLETERNICA	0,32777	0,28660	0,15387	0,12651	0,03556
LUDBREG	0,12450	0,13863	0,04817	0,16336	0,03693
MALI LOŠINJ	0,19203	0,09030	0,12711	0,10870	0,03755
OBROVAC	0,34094	0,13937	0,09136	0,08759	0,04131
ZLATAR	0,30887	0,18697	0,10326	0,07392	0,04188
OPUZEN	0,07285	0,08745	0,09212	0,12178	0,04393
DONJI MIHOLJAC	0,19107	0,28611	0,41393	0,40942	0,04497

MAKARSKA	0,05858	0,05257	0,05246	0,05541	0,04684
PAG	0,13665	0,06465	0,08672	0,19647	0,04940
SENJ	0,07899	0,03058	0,08293	0,09351	0,05154
TROGIR	0,44106	0,45219	0,33661	0,28903	0,05350
BELI MANASTIR	0,03312	0,02196	0,00210	0,00194	0,05386
DRNIŠ	0,08029	0,12829	0,06816	0,14592	0,05439
KUTINA	0,02558	0,03541	0,02906	0,05922	0,05587
KNIN	0,31084	0,31887	0,20257	0,14881	0,05993
OROSLAVJE	0,05792	0,03568	0,01480	0,03831	0,06119
CRES	0,00123	0,00000	0,01105	0,01514	0,06654
PAZIN	0,08226	0,08354	0,08427	0,09997	0,07257
VIS	0,08030	0,12137	0,10450	0,12446	0,07440
ČABAR	0,26926	0,19462	0,58665	0,50234	0,07948
GRUBIŠNO POLJE	0,10338	0,09069	0,06347	0,05131	0,08133
GOSPIĆ	0,00011	0,01285	0,03462	0,08610	0,08673
PETRINJA	0,00768	0,08684	0,00000	0,21209	0,08734
VODICE	0,07747	0,05272	0,08076	0,06896	0,09272
ČAKOVEC	0,04967	0,10581	0,09231	0,06123	0,09534
ILOK	0,27923	0,32353	0,21182	0,21699	0,09734
VARAŽDIN	0,16797	0,19091	0,10580	0,10350	0,10076
LIPIK	0,02376	0,05294	0,11945	0,18034	0,10486
VINKOVCI	0,00000	0,06576	0,04379	0,08149	0,10557
ČAZMA	0,09022	0,07619	0,11005	0,11452	0,10665
METKOVIĆ	0,21681	0,10864	0,08315	0,12798	0,10714
NOVI VINODOLSKI	0,29217	0,28885	0,29529	0,22356	0,10999
ZADAR	0,13935	0,16045	0,12845	0,13990	0,12262
ŠIBENIK	0,09583	0,17140	0,21209	0,24168	0,12958
DELNICE	0,21963	0,15159	0,15166	0,20569	0,13588
VODNJAN	0,15633	0,13869	0,15989	0,12243	0,13956
RAB	0,26689	0,22529	0,12419	0,13192	0,15227
RIJEKA	0,20427	0,24792	0,25294	0,27861	0,17427
VALPOVO	0,18195	0,19537	0,15135	0,20477	0,17431
PLOČE	0,38179	0,33484	0,28163	0,23229	0,18141
PRELOG	0,04042	0,06283	0,03100	0,18218	0,18954
BAKAR	0,00450	0,00000	0,00000	0,00000	0,19007
VRGORAC	0,15686	0,18687	0,17864	0,17396	0,19669
VRLIKA	0,08006	0,09279	0,08907	0,12647	0,22921
OMIŠ	0,37492	0,47179	0,25321	0,22785	0,23465
BIOGRAD NA MORU	0,39164	0,41751	0,32483	0,23903	0,24028
OTOK	0,38719	0,39701	0,28776	0,38897	0,28528
OTOČAC	0,57294	0,37547	0,28596	0,26666	0,29826
HRVATSKA KOSTAJNICA	0,36652	0,24222	0,29305	0,47691	0,32651
SUPETAR	0,30907	0,29790	0,47717	0,35945	0,46571

Prilog 4. Kretanje procijenjenog broj stanovnika gradova od 2014. do 2018. godine

Grad	2014.	2015.	2016.	2017.	2018.
DUGO SELO	18.323	18.240	18.143	18.039	18.014
IVANIĆ-GRAD	14.265	14.065	13.858	13.697	13.641
JASTREBARSKO	15.583	15.431	15.293	15.198	15.105
SAMOBOR	37.801	37.728	37.598	37.499	37.666
SVETA NEDJELJA	18.334	18.292	18.298	18.305	18.370
SVETI IVAN ZELINA	15.642	15.377	15.190	15.040	14.907
VELIKA GORICA	63.984	63.651	63.323	62.785	62.497
VRBOVEC	14.685	14.523	14.341	14.146	14.108
ZAPREŠIĆ	25.380	25.319	25.181	25.045	24.968
DONJA STUBICA	5.752	5.842	5.809	5.767	5.874
KLANJEC	2.800	2.765	2.738	2.679	2.640
KRAPINA	12.350	12.243	12.132	12.043	11.871
OROSLAVJE	6.118	6.108	6.074	6.046	5.983
PREGRADA	6.378	6.287	6.226	6.104	5.989
ZABOK	8.963	8.881	8.840	8.788	8.756
ZLATAR	5.969	5.855	5.738	5.659	5.602
GLINA	7.989	7.694	7.408	7.008	6.824
HRVATSKA KOSTAJNICA	2.405	2.312	2.197	2.044	1.990
KUTINA	22.164	21.796	21.427	20.937	20.616
NOVSKA	12.973	12.738	12.453	12.005	11.769
PETRINJA	23.236	22.801	22.128	21.350	20.758
POPOVAČA	11.659	11.488	11.367	11.162	10.988
SISAK	45.844	45.081	44.411	43.543	42.844
DUGA RESA	10.940	10.843	10.776	10.673	10.583
KARLOVAC	53.770	53.134	52.488	51.864	51.447
OGULIN	13.571	13.379	13.182	12.993	12.847
OZALJ	6.570	6.457	6.316	6.244	6.138
SLUNJ	4.592	4.476	4.361	4.261	4.174
IVANEC	13.519	13.392	13.326	13.204	13.087
LEPOGLAVA	7.989	7.909	7.785	7.668	7.531
LUDBREG	9.094	8.953	8.801	8.715	8.681
NOVI MAROF	12.973	12.802	12.618	12.394	12.257
VARAŽDIN	46.476	46.319	46.294	45.938	45.989
VARAŽDINSKE TOPLICE	6.237	6.120	6.020	5.915	5.849
ĐURĐEVAC	8.088	8.020	7.903	7.810	7.768
KOPRIVNICA	31.012	30.864	30.466	30.217	29.945
KRIŽEVCI	20.778	20.602	20.303	20.094	19.960
BJELOVAR	39.551	39.180	38.783	38.433	38.250
ČAZMA	7.744	7.655	7.545	7.398	7.280
DARUVAR	11.280	11.041	10.839	10.651	10.506

GAREŠNICA	9.865	9.649	9.449	9.204	9.013
GRUBIŠNO POLJE	6.070	5.917	5.745	5.635	5.499
BAKAR	8.264	8.231	8.173	8.127	8.114
CRES	2.956	2.937	2.903	2.887	2.873
CRIKVENICA	11.234	11.067	10.905	10.825	10.737
ČABAR	3.581	3.498	3.388	3.271	3.198
DELNICE	5.776	5.693	5.586	5.502	5.450
KASTAV	10.688	10.705	10.666	10.757	10.898
KRALJEVICA	4.566	4.520	4.485	4.470	4.454
KRK	6.644	6.675	6.748	6.810	6.878
MALI LOŠINJ	8.175	8.147	8.115	8.002	7.939
NOVI VINODOLSKI	5.090	4.983	4.925	4.834	4.844
OPATIJA	11.449	11.305	11.145	10.988	10.969
RAB	8.152	8.117	8.027	7.957	7.918
RIJEKA	123.725	121.975	120.855	119.161	117.415
VRBOVSKO	4.714	4.578	4.441	4.306	4.170
GOSPIĆ	12.280	12.186	12.067	11.901	11.826
NOVALJA	3.942	3.932	3.961	3.938	4.030
OTOČAC	9.384	9.238	9.144	9.023	8.942
SENJ	6.856	6.685	6.561	6.438	6.283
ORAHOVICA	5.072	4.962	4.844	4.744	4.648
SLATINA	13.181	12.904	12.697	12.270	12.117
VIROVITICA	21.160	20.893	20.556	20.237	19.975
KUTJEVO	5.970	5.747	5.566	5.370	5.151
LIPIK	5.639	5.564	5.496	5.224	5.121
PAKRAC	7.720	7.462	7.263	6.895	6.749
PLETERNICA	10.906	10.662	10.284	9.981	9.658
POŽEGA	25.455	24.978	24.522	23.968	23.572
NOVA GRADIŠKA	13.653	13.452	13.133	12.723	12.406
SLAVONSKI BROD	57.797	56.769	55.825	54.367	53.614
BENKOVAC	10.550	10.177	9.879	9.538	9.289
BIOGRAD NA MORU	5.746	5.739	5.731	5.800	5.876
NIN	2.854	2.876	2.908	2.908	2.903
OBROVAC	3.980	3.844	3.778	3.709	3.648
PAG	3.745	3.722	3.700	3.683	3.721
ZADAR	75.537	75.346	75.437	75.200	75.194
BELI MANASTIR	9.439	9.231	8.970	8.549	8.374
BELIŠĆE	10.488	10.333	10.150	9.874	9.641
DONJI MIHOLJAC	9.186	9.054	8.910	8.690	8.535
ĐAKOVO	27.238	26.865	26.433	25.813	25.412
NAŠICE	16.212	16.016	15.798	15.565	15.375
OSIJEK	106.610	105.921	104.638	103.162	101.911
VALPOVO	11.262	11.095	10.937	10.697	10.474

DRNIŠ	6.989	6.804	6.616	6.350	6.198
KNIN	13.525	13.095	12.594	11.944	11.590
SKRADIN	3.549	3.451	3.348	3.330	3.229
ŠIBENIK	45.714	45.294	45.008	44.771	44.539
VODICE	9.321	9.327	9.289	9.288	9.286
ILOK	6.351	6.209	6.030	5.599	5.436
OTOK	6.014	5.836	5.633	5.447	5.238
VINKOVCI	35.470	35.288	34.986	34.300	33.920
VUKOVAR	25.511	24.938	24.219	23.061	22.631
ŽUPANJA	11.579	11.196	10.644	10.074	9.709
HVAR	4.410	4.440	4.468	4.469	4.472
IMOTSKI	10.525	10.587	10.298	10.090	9.954
KAŠTELA	40.501	40.586	40.658	40.630	40.653
KOMIŽA	1.556	1.524	1.500	1.498	1.489
MAKARSKA	14.217	14.217	14.317	14.284	14.261
OMIŠ	14.903	14.798	14.815	14.739	14.661
SINJ	24.742	24.617	24.476	24.290	24.236
SOLIN	25.349	25.564	25.892	26.006	26.372
SPLIT	174.333	173.109	172.362	171.281	170.419
STARI GRAD	2.848	2.867	2.866	2.861	2.879
SUPETAR	4.326	4.362	4.382	4.389	4.410
TRILJ	8.713	8.621	8.540	8.388	8.268
TROGIR	13.229	13.223	13.142	13.081	12.942
VIS	2.032	2.035	2.028	2.048	2.047
VRGORAC	6.040	5.911	5.754	5.623	5.596
VRLIKA	1.864	1.930	1.879	1.824	1.761
BUJE	5.120	5.105	5.039	4.987	4.919
BUZET	6.092	6.055	6.057	6.028	6.023
LABIN	11.290	11.178	11.057	11.012	10.922
NOVIGRAD	2.280	2.220	2.191	2.133	2.100
PAZIN	8.502	8.442	8.383	8.363	8.367
POREČ	16.937	17.000	17.127	17.279	17.502
PULA	56.676	56.540	56.527	56.374	56.388
ROVINJ	14.441	14.417	14.451	14.449	14.501
UMAG	13.692	13.773	13.828	13.890	13.894
VODNJAN	6.218	6.237	6.353	6.352	6.384
DUBROVNIK	43.400	43.697	43.950	44.149	44.376
KORČULA	5.606	5.591	5.550	5.530	5.554
METKOVIĆ	16.743	16.619	16.371	16.290	16.257
OPUZEN	3.176	3.186	3.164	3.142	3.135
PLOČE	9.514	9.415	9.141	9.031	8.929
ČAKOVEC	27.852	27.868	27.801	27.724	27.682
MURSKO SREDIŠĆE	6.230	6.215	6.193	6.092	6.038
PRELOG	7.740	7.690	7.671	7.632	7.595
ZAGREB	799.999	801.349	803.647	803.900	806.341

Prilog 5. Bonfferonijev post-hoc test

Pairwise Comparisons

Measure: MEASURE_1: *Default_proxy*

(I) godine	(J) godine	Mean Difference (I-J)	Std. Error	Sig.[b]	95 % Confidence Interval for Difference[b]	
					Lower Bound	Upper Bound
1	2	.012	.006	.294	-.004	.029
	3	.027*	.007	.002	.007	.048
	4	.020	.008	.142	-.003	.043
	5	.050*	.009	.000	.023	.076
2	1	-.012	.006	.294	-.029	.004
	3	.015	.006	.076	-.001	.031
	4	.008	.006	1.000	-.011	.026
	5	.037*	.008	.000	.014	.060
3	1	-.027*	.007	.002	-.048	-.007
	2	-.015	.006	.076	-.031	.001
	4	-.007	.004	.706	-.019	.004
	5	.022*	.007	.025	.002	.043
4	1	-.020	.008	.142	-.043	.003
	2	-.008	.006	1.000	-.026	.011
	3	.007	.004	.706	-.004	.019
	5	.030*	.007	.000	.011	.049
5	1	-.050*	.009	.000	-.076	-.023
	2	-.037*	.008	.000	-.060	-.014
	3	-.022*	.007	.025	-.043	-.002
	4	-.030*	.007	.000	-.049	-.011

Based on estimated marginal means

*. The mean difference is significant at the

b. Adjustment for multiple comparisons: Bonferroni.

Pairwise Comparisons

Measure: MEASURE 1: *ppor pp*

(I) godine	(J) godine	Mean Difference (I-J)	Std. Error	Sig.[b]	95 % Confidence Interval for Difference[b]	
					Lower Bound	Upper Bound
1	2	.060*	.008	.000	.038	.082
	3	.046*	.008	.000	.023	.068
	4	.063*	.008	.000	.041	.086
	5	-.063*	.010	.000	-.092	-.035
2	1	-.060*	.008	.000	-.082	-.038
	3	-.015	.006	.184	-.032	.003
	4	.003	.006	1.000	-.014	.020
	5	-.124*	.012	.000	-.159	-.088
3	1	-.046*	.008	.000	-.068	-.023
	2	.015	.006	.184	-.003	.032
	4	.018*	.006	.038	.001	.035
	5	-.109*	.013	.000	-.145	-.073
4	1	-.063*	.008	.000	-.086	-.041
	2	-.003	.006	1.000	-.020	.014
	3	-.018*	.006	.038	-.035	-.001
	5	-.126*	.013	.000	-.163	-.090
5	1	.063*	.010	.000	.035	.092
	2	.124*	.012	.000	.088	.159
	3	.109*	.013	.000	.073	.145
	4	.126*	.013	.000	.090	.163

Based on estimated marginal means

*. The mean difference is significant at the

b. Adjustment for multiple comparisons: Bonferroni.

Pairwise Comparisons

Measure: MEASURE 1 *mpp pp*

(I) godine	(J) godine	Mean Difference (I-J)	Std. Error	Sig.[b]	95 % Confidence Interval for Difference[b]	
					Lower Bound	Upper Bound
1	2	.007	.008	1.000	-.015	.028
	3	.031*	.008	.002	.008	.054
	4	.020	.010	.504	-.009	.050
	5	.039	.014	.057	-.001	.079
2	1	-.007	.008	1.000	-.028	.015
	3	.024*	.006	.000	.008	.040
	4	.013	.008	.952	-.009	.036
	5	.032	.013	.154	-.005	.070
3	1	-.031*	.008	.002	-.054	-.008
	2	-.024*	.006	.000	-.040	-.008
	4	-.011	.006	.707	-.028	.006
	5	.008	.011	1.000	-.023	.040
4	1	-.020	.010	.504	-.050	.009
	2	-.013	.008	.952	-.036	.009
	3	.011	.006	.707	-.006	.028
	5	.019	.012	1.000	-.015	.053
5	1	-.039	.014	.057	-.079	.001
	2	-.032	.013	.154	-.070	.005
	3	-.008	.011	1.000	-.040	.023
	4	-.019	.012	1.000	-.053	.015

Based on estimated marginal means

*. The mean difference is significant at the

b. Adjustment for multiple comparisons: Bonferroni.

Pairwise Comparisons

Measure: MEASURE_1 *okz_uo*

(I) godine	(J) godine	Mean Difference (I-J)	Std. Error	Sig.[b]	95 % Confidence Interval for Difference[b]	
					Lower Bound	Upper Bound
1	2	-.015	.015	1.000	-.057	.027
	3	.007	.017	1.000	-.042	.056
	4	.022	.021	1.000	-.037	.081
	5	.066*	.023	.043	.001	.132
2	1	.015	.015	1.000	-.027	.057
	3	.022	.015	1.000	-.022	.066
	4	.037	.020	.648	-.020	.093
	5	.081*	.023	.006	.015	.147
3	1	-.007	.017	1.000	-.056	.042
	2	-.022	.015	1.000	-.066	.022
	4	.015	.012	1.000	-.020	.049
	5	.059*	.018	.016	.007	.111
4	1	-.022	.021	1.000	-.081	.037
	2	-.037	.020	.648	-.093	.020
	3	-.015	.012	1.000	-.049	.020
	5	.044*	.015	.038	.001	.087
5	1	-.066*	.023	.043	-.132	-.001
	2	-.081*	.023	.006	-.147	-.015
	3	-.059*	.018	.016	-.111	-.007
	4	-.044*	.015	.038	-.087	-.001

Based on estimated marginal means

*. The mean difference is significant at the

b. Adjustment for multiple comparisons: Bonferroni.

Pairwise Comparisons

Measure: MEASURE_1 *potp_pp*

(I) godine	(J) godine	Mean Difference (I-J)	Std. Error	Sig.[b]	95 % Confidence Interval for Difference[b]	
					Lower Bound	Upper Bound
1	2	-.024*	.008	.035	-.047	-.001
	3	.001	.009	1.000	-.024	.027
	4	.003	.011	1.000	-.028	.034
	5	.096*	.013	.000	.060	.132
2	1	.024*	.008	.035	.001	.047
	3	.025*	.007	.009	.004	.046
	4	.027*	.009	.049	5.274E-5	.054
	5	.120*	.012	.000	.085	.156
3	1	-.001	.009	1.000	-.027	.024
	2	-.025*	.007	.009	-.046	-.004
	4	.002	.007	1.000	-.019	.022
	5	.095*	.010	.000	.066	.124
4	1	-.003	.011	1.000	-.034	.028
	2	-.027*	.009	.049	-.054	-5.274E-5
	3	-.002	.007	1.000	-.022	.019
	5	.093*	.012	.000	.060	.127
5	1	-.096*	.013	.000	-.132	-.060
	2	-.120*	.012	.000	-.156	-.085
	3	-.095*	.010	.000	-.124	-.066
	4	-.093*	.012	.000	-.127	-.060

Based on estimated marginal means

*. The mean difference is significant at the

b. Adjustment for multiple comparisons: Bonferroni.

Pairwise Comparisons

Measure: MEASURE 1 *ki ko*

(I) godine	(J) godine	Mean Difference (I-J)	Std. Error	Sig.[a]	95 % Confidence Interval for Difference[a]	
					Lower Bound	Upper Bound
1	2	-1.935	1.394	1.000	-5.918	2.048
	3	-.214	1.314	1.000	-3.968	3.540
	4	.807	1.458	1.000	-3.359	4.973
	5	3.326	1.702	.528	-1.535	8.188
2	1	1.935	1.394	1.000	-2.048	5.918
	3	1.721	2.339	1.000	-4.962	8.404
	4	2.742	2.562	1.000	-4.576	10.060
	5	5.261	2.835	.658	-2.839	13.362
3	1	.214	1.314	1.000	-3.540	3.968
	2	-1.721	2.339	1.000	-8.404	4.962
	4	1.021	.850	1.000	-1.407	3.448
	5	3.540	1.243	.051	-.011	7.091
4	1	-.807	1.458	1.000	-4.973	3.359
	2	-2.742	2.562	1.000	-10.060	4.576
	3	-1.021	.850	1.000	-3.448	1.407
	5	2.519	.931	.077	-.139	5.178
5	1	-3.326	1.702	.528	-8.188	1.535
	2	-5.261	2.835	.658	-13.362	2.839
	3	-3.540	1.243	.051	-7.091	.011
	4	-2.519	.931	.077	-5.178	.139

Based on estimated marginal means

a. Adjustment for multiple comparisons: Bonferroni.

Pairwise Comparisons

Measure: MEASURE 1 *got rp*

(I) godine	(J) godine	Mean Difference (I-J)	Std. Error	Sig.[b]	95 % Confidence Interval for Difference[b]	
					Lower Bound	Upper Bound
1	2	.002	.009	1.000	-.024	.028
	3	-.024	.012	.422	-.057	.009
	4	-.058*	.017	.010	-.107	-.009
	5	-.135*	.025	.000	-.207	-.064
2	1	-.002	.009	1.000	-.028	.024
	3	-.026	.010	.101	-.054	.002
	4	-.060*	.018	.011	-.111	-.009
	5	-.137*	.025	.000	-.209	-.066
3	1	.024	.012	.422	-.009	.057
	2	.026	.010	.101	-.002	.054
	4	-.034	.017	.416	-.082	.013
	5	-.112*	.022	.000	-.175	-.048
4	1	.058*	.017	.010	.009	.107
	2	.060*	.018	.011	.009	.111
	3	.034	.017	.416	-.013	.082
	5	-.077*	.022	.007	-.141	-.014
5	1	.135*	.025	.000	.064	.207
	2	.137*	.025	.000	.066	.209
	3	.112*	.022	.000	.048	.175
	4	.077*	.022	.007	.014	.141

Based on estimated marginal means

*. The mean difference is significant at the

b. Adjustment for multiple comparisons: Bonferroni.

Pairwise Comparisons

Measure: MEASURE 1 *trans*

(I) godine	(J) godine	Mean Difference (I-J)	Std. Error	Sig.[b]	95 % Confidence Interval for Difference[b]	
					Lower Bound	Upper Bound
1	2	-.039	.101	1.000	-.328	.250
	3	-.375*	.115	.014	-.703	-.047
	4	-.984*	.133	.000	-1.363	-.605
	5	-1.359*	.138	.000	-1.755	-.964
2	1	.039	.101	1.000	-.250	.328
	3	-.336*	.101	.011	-.623	-.048
	4	-.945*	.122	.000	-1.293	-.598
	5	-1.320*	.125	.000	-1.677	-.963
3	1	.375*	.115	.014	.047	.703
	2	.336*	.101	.011	.048	.623
	4	-.609*	.110	.000	-.925	-.294
	5	-.984*	.115	.000	-1.312	-.657
4	1	.984*	.133	.000	.605	1.363
	2	.945*	.122	.000	.598	1.293
	3	.609*	.110	.000	.294	.925
	5	-.375*	.092	.001	-.638	-.112
5	1	1.359*	.138	.000	.964	1.755
	2	1.320*	.125	.000	.963	1.677
	3	.984*	.115	.000	.657	1.312
	4	.375*	.092	.001	.112	.638

Based on estimated marginal means

*. The mean difference is significant at the

b. Adjustment for multiple comparisons: Bonferroni.

Prilog 6. Detaljni prikaz modeliranja *početne vrijednosti (intercept)*

Model Summary[d]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics					Durbin-Watson
					R Square Change	F Change	df1	df2	Sig. F Change	
1	.668[a]	.446	.437	.09096	.446	50.339	2	125	.000	
2	.712[b]	.507	.483	.08719	.061	3.761	4	121	.006	
3	.714[c]	.510	.482	.08730	.003	.688	1	120	.409	2.215

a. Predictors: (Constant), MPP_prosjek, PPOR_prosjek
b. Predictors: (Constant), MPP_prosjek, PPOR_prosjek, POTP_prosjek, OKZ_prosjek, KI_prosjek, GOT_prosjek
c. Predictors: (Constant), MPP_prosjek, PPOR_prosjek, POTP_prosjek, OKZ_prosjek, KI_prosjek, GOT_prosjek, TRANS_prosjek
d. Dependent Variable: Intercept

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	.833	2	.417	50.339	.000[b]
	Residual	1.034	125	.008		
	Total	1.867	127			
2	Regression	.947	6	.158	20.770	.000[c]
	Residual	.920	121	.008		
	Total	1.867	127			
3	Regression	.953	7	.136	17.855	.000[d]
	Residual	.915	120	.008		
	Total	1.867	127			

a. Dependent Variable: Intercept
b. Predictors: (Constant), MPP_prosjek, PPOR_prosjek
c. Predictors: (Constant), MPP_prosjek, PPOR_prosjek, POTP_prosjek, OKZ_prosjek, KI_prosjek, GOT_prosjek
d. Predictors: (Constant), MPP_prosjek, PPOR_prosjek, POTP_prosjek, OKZ_prosjek, KI_prosjek, GOT_prosjek, TRANS_prosjek

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	.016	.036		.436	.663		
	PPOR_prosjek	-.150	.070	-.145	-2.157	.033	.977	1.023
	MPP_prosjek	.724	.077	.630	9.361	.000	.977	1.023
2	(Constant)	-.021	.048		-.436	.664		
	PPOR_prosjek	-.119	.071	-.115	-1.664	.099	.859	1.164
	MPP_prosjek	.697	.092	.607	7.568	.000	.632	1.582
	OKZ_prosjek	-.019	.031	-.042	-.620	.536	.874	1.144
	POTP_prosjek	.106	.045	.161	2.369	.019	.886	1.128
	KI_prosjek	-.001	.001	-.169	-2.400	.018	.821	1.218
	GOT_prosjek	.117	.065	.138	1.818	.072	.706	1.417
3	(Constant)	-.013	.049		-.259	.796		
	PPOR_prosjek	-.098	.076	-.094	-1.291	.199	.764	1.310
	MPP_prosjek	.695	.092	.605	7.530	.000	.631	1.584
	OKZ_prosjek	-.016	.031	-.037	-.537	.592	.866	1.154
	POTP_prosjek	.101	.045	.153	2.232	.027	.870	1.149
	KI_prosjek	-.001	.001	-.161	-2.256	.026	.805	1.243
	GOT_prosjek	.119	.065	.140	1.845	.068	.705	1.419
	TRANS_prosjek	-.006	.007	-.059	-.829	.409	.819	1.221

a. Dependent Variable: Intercept

Collinearity Diagnostics[a]

Model	Dimension	Eigenvalue	Condition Index	Variance Proportions							
				(Constant)	PPOR_prosjek	MPP_prosjek	OKZ_prosjek	POTP_prosjek	KI_prosjek	GOT_prosjek	TRANS_prosjek
1	1	2.433	1.000	.01	.01	.06					
	2	.541	2.121	.01	.02	.88					
	3	.027	9.576	.98	.98	.06					
2	1	4.883	1.000	.00	.00	.01	.01	.01	.01	.01	
	2	.898	2.332	.00	.00	.29	.00	.00	.09	.05	
	3	.438	3.340	.00	.00	.02	.00	.01	.63	.22	
	4	.402	3.485	.00	.01	.03	.37	.09	.04	.15	
	5	.223	4.683	.00	.00	.34	.00	.74	.18	.16	
	6	.139	5.918	.02	.14	.10	.56	.11	.02	.17	
	7	.017	16.705	.98	.84	.21	.05	.03	.03	.24	
3	1	5.753	1.000	.00	.00	.00	.01	.01	.01	.01	.00
	2	.898	2.531	.00	.00	.30	.00	.01	.09	.05	.00
	3	.450	3.575	.00	.00	.04	.02	.05	.63	.07	.01
	4	.416	3.720	.00	.00	.01	.25	.07	.01	.32	.01
	5	.224	5.066	.00	.00	.31	.01	.73	.19	.12	.01
	6	.180	5.656	.00	.03	.11	.62	.01	.01	.19	.14
	7	.062	9.633	.05	.22	.02	.03	.09	.03	.01	.83
	8	.017	18.136	.95	.73	.21	.05	.03	.03	.24	.00

a. Dependent Variable: Intercept

Residuals Statistics[a]

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	-.1727	.4210	.0000	.08661	128
Residual	-.19679	.42021	.00000	.08486	128
Std. Predicted Value	-1.994	4.861	.000	1.000	128
Std. Residual	-2.254	4.813	.000	.972	128

a. Dependent Variable: Intercept

Prilog 7. Detaljni prikaz modeliranja *dinamike kretanja (slope)*

Model Summary[d]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics					Durbin-Watson
					R Square Change	F Change	df1	df2	Sig. F Change	
1	.454[a]	.206	.193	.01735	.206	16.187	2	125	.000	
2	.532[b]	.283	.247	.01676	.077	3.246	4	121	.014	
3	.533[c]	.284	.242	.01681	.001	.239	1	120	.626	2.226

a. Predictors: (Constant), MPP_prosjek, PPOR_prosjek
b. Predictors: (Constant), MPP_prosjek, PPOR_prosjek, POTP_prosjek, OKZ_prosjek, KI_prosjek, GOT_prosjek
c. Predictors: (Constant), MPP_prosjek, PPOR_prosjek, POTP_prosjek, OKZ_prosjek, KI_prosjek, GOT_prosjek, TRANS_prosjek
d. Dependent Variable: Slope

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	.010	2	.005	16.187	.000[b]
	Residual	.038	125	.000		
	Total	.047	127			
2	Regression	.013	6	.002	7.947	.000[c]
	Residual	.034	121	.000		
	Total	.047	127			
3	Regression	.013	7	.002	6.803	.000[d]
	Residual	.034	120	.000		
	Total	.047	127			

a. Dependent Variable: Slope
b. Predictors: (Constant), MPP_prosjek, PPOR_prosjek
c. Predictors: (Constant), MPP_prosjek, PPOR_prosjek, POTP_prosjek, OKZ_prosjek, KI_prosjek, GOT_prosjek
d. Predictors: (Constant), MPP_prosjek, PPOR_prosjek, POTP_prosjek, OKZ_prosjek, KI_prosjek, GOT_prosjek, TRANS_prosjek

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	-.001	.007		-.190	.849		
	PPOR_prosjek	.016	.013	.094	1.166	.246	.977	1.023
	MPP_prosjek	-.079	.015	-.430	-5.329	.000	.977	1.023
2	(Constant)	.006	.009		.689	.492		
	PPOR_prosjek	.011	.014	.067	.803	.424	.859	1.164
	MPP_prosjek	-.075	.018	-.408	-4.208	.000	.632	1.582
	OKZ_prosjek	-.001	.006	-.011	-.138	.890	.874	1.144
	POTP_prosjek	-.020	.009	-.192	-2.343	.021	.886	1.128
	KI_prosjek	.000	.000	.213	2.504	.014	.821	1.218
	GOT_prosjek	-.021	.012	-.155	-1.688	.094	.706	1.417
3	(Constant)	.005	.009		.574	.567		
	PPOR_prosjek	.009	.015	.052	.592	.555	.764	1.310
	MPP_prosjek	-.074	.018	-.406	-4.178	.000	.631	1.584
	OKZ_prosjek	-.001	.006	-.015	-.184	.854	.866	1.154
	POTP_prosjek	-.020	.009	-.186	-2.248	.026	.870	1.149
	KI_prosjek	.000	.000	.207	2.402	.018	.805	1.243
	GOT_prosjek	-.021	.012	-.156	-1.700	.092	.705	1.419
	TRANS_prosjek	.001	.001	.042	.488	.626	.819	1.221

a. Dependent Variable: Slope

Collinearity Diagnostics[a]

Model	Dimension	Eigenvalue	Condition Index	Variance Proportions							
				(Constant)	PPOR_prosjek	MPP_prosjek	OKZ_prosjek	POTP_prosjek	KI_prosjek	GOT_prosjek	TRANS_prosjek
1	1	2.433	1.000	.01	.01	.06					
	2	.541	2.121	.01	.02	.88					
	3	.027	9.576	.98	.98	.06					
2	1	4.883	1.000	.00	.00	.01	.01	.01	.01	.01	
	2	.898	2.332	.00	.00	.29	.00	.00	.09	.05	
	3	.438	3.340	.00	.00	.02	.00	.01	.63	.22	
	4	.402	3.485	.00	.01	.03	.37	.09	.04	.15	
	5	.223	4.683	.00	.00	.34	.00	.74	.18	.16	
	6	.139	5.918	.02	.14	.10	.56	.11	.02	.17	
	7	.017	16.705	.98	.84	.21	.05	.03	.03	.24	
3	1	5.753	1.000	.00	.00	.00	.01	.01	.01	.01	.00
	2	.898	2.531	.00	.00	.30	.00	.01	.09	.05	.00
	3	.450	3.575	.00	.00	.04	.02	.05	.63	.07	.01
	4	.416	3.720	.00	.00	.01	.25	.07	.01	.32	.01
	5	.224	5.066	.00	.00	.31	.01	.73	.19	.12	.01
	6	.180	5.656	.00	.03	.11	.62	.01	.01	.19	.14
	7	.062	9.633	.05	.22	.02	.03	.09	.03	.01	.83
	8	.017	18.136	.95	.73	.21	.05	.03	.03	.24	.00

a. Dependent Variable: Slope

Residuals Statistics[a]

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	-.0450	.0309	.0000	.01029	128
Residual	-.08102	.03455	.00000	.01634	128
Std. Predicted Value	-4.369	3.006	.000	1.000	128
Std. Residual	-4.819	2.055	.000	.972	128

a. Dependent Variable: Slope

Prilog 8. Detaljni prikaz konačnog modela

Model Summary[c]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics					Durbin-Watson
					R Square Change	F Change	df1	df2	Sig. F Change	
1	.757[a]	.573	.566	.06281	.573	83.883	2	125	.000	
2	.775[b]	.601	.588	.06122	.028	4.280	2	123	.016	2.218

a. Predictors: (Constant), MPP_prosjek, PPOR_prosjek
b. Predictors: (Constant), MPP_prosjek, PPOR_prosjek, POTP_prosjek, KI_prosjek

c. Dependent Variable: default_proxy_svi

ANOVA[a]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	.662	2	.331	83.883	.000[b]
	Residual	.493	125	.004		
	Total	1.155	127			
2	Regression	.694	4	.173	46.283	.000[c]
	Residual	.461	123	.004		
	Total	1.155	127			

a. Dependent Variable: default_proxy_svi
b. Predictors: (Constant), MPP_prosjek, PPOR_prosjek
c. Predictors: (Constant), MPP_prosjek, PPOR_prosjek, POTP_prosjek, KI_prosjek

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	.092	.025		3.728	.000		
	PPOR_prosjek	-.128	.048	-.158	-2.665	.009	.977	1.023
	MPP_prosjek	.647	.053	.717	12.127	.000	.977	1.023
2	(Constant)	.093	.027		3.399	.001		
	PPOR_prosjek	-.136	.048	-.167	-2.852	.005	.942	1.061
	MPP_prosjek	.587	.056	.650	10.440	.000	.837	1.194
	POTP_prosjek	.071	.031	.136	2.273	.025	.903	1.107
	KI_prosjek	-.001	.000	-.145	-2.327	.022	.841	1.189

a. Dependent Variable: default_proxy_svi

Collinearity Diagnostics[a]

Model	Dimension	Eigenvalue	Condition Index	Variance Proportions				
				(Constant)	PPOR_prosjek	MPP_prosjek	POTP_prosjek	KI_prosjek
1	1	2.433	1.000	.01	.01	.06		
	2	.541	2.121	.01	.02	.88		
	3	.027	9.576	.98	.98	.06		
2	1	3.638	1.000	.00	.00	.02	.02	.02
	2	.783	2.155	.00	.00	.40	.00	.26
	3	.330	3.320	.01	.04	.41	.00	.54
	4	.225	4.018	.01	.02	.11	.94	.11
	5	.023	12.567	.98	.94	.07	.04	.06

a. Dependent Variable: default_proxy_svi

Residuals Statistics[a]

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	-.0242	.4496	.0814	.07392	128
Residual	-.11612	.29768	.00000	.06025	128
Std. Predicted Value	-1.429	4.981	.000	1.000	128
Std. Residual	-1.897	4.863	.000	.984	128

a. Dependent Variable: default_proxy_svi

David Krmpotić
Sv. Petka 5, 31000 Osijek
Mob: 098 640 555
Mail: david.krmpotic@osijek.hr

Životopis autora

Rođen sam 1. lipnja 1982. godine u Osijeku (Republika Hrvatska). Nakon završene III. (prirodoslovno-matematičke) gimnazije u Osijeku 2001. godine, završavam diplomski studij na Sveučilištu J. J. Strossmayera u Osijeku, na Ekonomskom fakultetu u Osijeku 2006. godine i stječem akademski naziv diplomirani ekonomist, smjer *Financijski management*. Na istom fakultetu 2008. godine upisujem Poslijediplomski specijalistički studij *Financije i bankarstvo* te sam 2015. godine, nakon obrane završnog rada, stekao akademski naziv sveučilišni specijalist financija i bankarstva (univ. spec. oec.). S namjerom daljnjeg usavršavanja 2012. godine, upisujem i Poslijediplomski doktorski studij *Management* na Ekonomskom fakultetu u Osijeku, na kojem sam položio sve kolegije propisane programom studija te napisao doktorski rad naziva *Utvrđivanje čimbenika neplaćanja obveza gradova u Republici Hrvatskoj* te stekao akademski naziv doktora znanosti (dr.sc.).

Radno iskustvo

Ubrzo nakon završetka diplomskog studija zapošljavam se u Slavonskoj banci u Osijeku te do spajanja s Hypo-Alpe-Adria Bank d.d. radim kao suradnik u Kontrolingu. Tijekom rada u Slavonskoj banci uspješno sam položio ispite za brokera i investicijskog savjetnika u organizaciji Hrvatske agencije za nadzor financijskih usluga u Zagrebu. U travnju 2009. godine postajem voditelj Razvoja, planiranja i analize u sektoru Poslovanja s javnim institucijama u Hypo-Alpe-Adria Bank d.d. iz Zagreba, 2010. godine postajem voditelj Upravljanja i nadzora mreže u istom sektoru te krajem 2011. godine imenovan sam direktorom Planiranja i kontrolinga prodaje u navedenoj banci. U lipnju 2012. godine zapošljavam se kao Financijski direktor u trgovačkom društvu Borovo-Poslovni centar d.o.o. iz Vukovara te radim i kao pomoćnik generalnog direktora trgovačkog društva Borovo d.d. iz Vukovara. Uz to obavljam i funkciju predsjednika nadzornog odbora u šest tvrtki kćeri trgovačkog društva Borovo d.d. iz Vukovara. Od rujna 2013. godine do danas obnašam dužnost pročelnika Upravnog odjela za financije i nabavu kao zaposlenik gradske uprave Grada Osijeka. Predsjednik sam nadzornog odbora trgovačkog društva Vodovod-Osijek d.o.o. i Zajednice športskih udruga Grada Osijeka,

te član Upravnog vijeća Zaklade Srce grada Osijeka i Izvršnog odbora Udruge računovođa i financijskih djelatnika Osijek. Član sam i revizorskog odbora Zagrebačkog holdinga d.o.o. U 9. sazivu Hrvatskog sabora bio sam vanjski član Odbora za financije i državni proračun.

Znanstveni interes usmjeren mi je na financiranje i fiskalnu autonomiju lokalnih jedinica vlasti, proučavanje financijskih kretanja jedinica lokalne samouprave, upravljanje likvidnošću u sustavu javnih financija te predviđanje financijskog stanja gradova u Republici Hrvatskoj.

Popis objavljenih radova:

1. Karačić, D.; Krmpotić, D; Stojanović, S. (2020) *Sinergijski učinci obračunskog vođenja računa Grada Osijeka*. 10. međunarodna konferencija „Razvoj javne uprave“, zbornik radova. Veleučilište „Lavoslav Ružička“ u Vukovaru, str. 107-115.
2. Krmpotić, D.; Ileš, M.; Bičvić, D. (2020) *THE IMPACT OF FISCAL AUTONOMY ON REGIONAL DEVELOPMENT IN THE REPUBLIC OF CROATIA* // 60th International Scientific Conference on Economic and Social Development / Vinogradova, Marina; Pochinok, Natalia; Bakhtina, Olga; Recker, Nicholas (ur.). Moskva: Varazdin Development and Entrepreneurship Agency, 2020. str. 39-48.
3. Karačić, D.; Krmpotić, D.; Ileš, M. (2020) *TAX AND OWN REVENUES OF LARGE CITIES IN THE REPUBLIC OF CROATIA* // Proceedings of the 14th Economics & Finance Conference / Altunoz, Utku; Beck, Jiri; Corbett, Bradley; Cadil, Jan; Tamas, Anca; Vojtovic, Sergej (ur.). Prag: International Institute of Social and Economic Sciences and International Society for Academic Studies, z. s., 2020. str. 89-98 doi:10.20472/EFC.2020.014.009.
4. Mahaček, D.; Krmpotić, D.; Liović, D. (2015) *Audit of revenues and receipts of local and regional self-government units with regard to tax revenues*. Mašek Tonković, A. (ur.) 4. međunarodni znanstveni simpozij Gospodarstvo istočne Hrvatske – vizija i razvoj : zbornik radova = 4th International scientific symposium Economy of eastern Croatia – vision and growth. Osijek, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet, str. 370-384.