Odrednice proračunske transparentnosti hrvatskih gradova

Artuković, Iva

Master's thesis / Diplomski rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Science / Sveučilište u Zagrebu, Prirodoslovno-matematički fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:217:635982

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-07-18**

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb

SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
MATEMATIČKI ODSJEK

Iva Artuković

ODREDNICE PRORAČUNSKE TRANSPARENTNOSTI HRVATSKIH GRADOVA

Diplomski rad

Voditelj rada:

Prof. dr. sc. Katarina Ott

Zagreb, rujan 2021.

Ovaj diplomski rad obranjen je dana _____ pred ispitnim povjerenstvom u sastavu:

1._____,predsjednik

2._____,član

3._____,član

Povjerenstvo je rad ocijenilo ocjenom _____ .

Potpisi članova povjerenstva:

1. _____
2. _____
3. _____

SADRŽAJ

1. UVOD 5

2. PRORAČUNSKA TRANSPARENTNOST 7

2.1. Definicija pojmova transparentnosti i proračunske transparentnosti 7

2.2. Teorijski pristup 9

2.3. Jedinice lokalne samouprave u RH 12

2.4. Proračunska transparentnost u RH 12

2.5. Hipoteze 14

3. METODOLOGIJA 17

3.1. Generalizirani linearni modeli 17

3.2. Poissonova regresija 20

3.3. Metoda maksimalne vjerodostojnosti 22

3.4. Testovi prilagodbe modela 23

3.5. Automatizirane funkcije 25

4. PODACI 27

4.1. Zavisna varijabla 27

4.2. Nezavisne varijable 31

5. EMPIRIJSKA ANALIZA NA PRIMJERU SVIH HRVATSKIH GRADOVA 34

5.1. Statistička obilježja podataka 34

5.2. Korelacijska matrica 35

5.3. Jednostruka Poissonova regresija 37

5.4. Višestruka Poissonova regresija 39

5.5. Analiza i interpretacija rezultata 51

6. ZAKLJUČAK 55

LITERATURA 57

SAŽETAK 61

SUMMARY 62

ŽIVOTOPIS 63

1. UVOD

Teško je pronaći jedinstvenu mjeru koja bi ju savršeno predstavljala, pa ni sama definicija pojma transparentnosti nije jedinstvena.

U ovom radu prikazan je uvid u nekoliko definicija proračunske transparentnosti, a kako je u RH inicijativu za istraživanje proračunske transparentnosti pokrenuo IJF koristi se baš njegova definicija.

Najviše se istraživanja proračunske transparentnosti u početcima provodilo na državnoj razini. No, danas se sve više proračunska transparentnost istražuje i na lokalnim razinama. Razvoj medija i njihova prisutnost na lokalnoj razini utjecala je na sve veću zainteresiranost građana za događanja u njihovoj sredini. Tako građani danas žele znati kuda odlazi njihov novac od poreza, odnosno u što se on ulaže.

Sljedećih je pet dokumenata bilo ključno za istraživanje u ovom radu: izvještaj o godišnjem izvršenju proračuna za 2018, polugodišnjem izvršenju proračuna za 2019., prijedlog proračuna za 2020., izglasani proračun za 2020. i proračunski vodič za građane za 2020.

Cilj ovog rada je otkriti odrednice proračunske transparentnosti 128 hrvatskih gradova. Promatrat će se utječu li nezavisne varijable negativno ili pozitivno na zavisnu varijablu OLBI; rod gradonačelnika, broj stanovnika, dohodak po stanovniku, prihodi po stanovniku, suficit ili deficit u ukupnim proračunskim prihodima i stopa nezaposlenosti.

Postavit će se nekoliko hipoteza te primjenom regresijske analize temeljene na Poissonovoj distribuciji utvrditi vrijede li one zaista. Isto tako utvrditi će se značaj različitih varijabli. Koristi se Poissonova distribucija jer se ona pokazala najboljom kada varijable poprimaju cjelobrojne vrijednosti, a u ovom slučaju to je OLBI koji poprima vrijednosti nula, jedan, dva, tri, četiri ili pet.

Nakon provedene regresijske analize dolazi se do rezultata kako varijabla dohodak po stanovniku ima statistički značajan pozitivan učinak na razinu

proračunske transparentnosti, dok ostale nezavisne varijable nemaju statistički značajan utjecaj na razinu proračunske transparentnosti.

Rad je strukturiran u nekoliko poglavlja. Prvo poglavlje daje uvid u temu rada. U drugom poglavlju riječ je o različitim definicijama proračunske transparentnosti, hipotezama rada, teorijskom pregledu literature te o istraživanju proračunske transparentnosti na razini hrvatskih lokalnih jedinica. U trećem poglavlju objašnjena je korištena metodologija, a u četvrtom poglavlju nalazi se detaljan opis varijabli korištenih u analizi. Zatim slijedi analiza dobivenih rezultata. Prvo je prikazana deskriptivna statistika varijabli te kreirana korelacijska matrica, a zatim se Poissonovom regresijom ispituju razni modeli te analiziraju sličnosti i razlike među odrednicama transparentnosti gradova u RH. Na kraju se donosi zaključak cijelog rada s njegovim ograničenjima i preporukama za daljnja istraživanja.

Svi su rezultati dobiveni korištenjem programskog jezika R.

2. PRORAČUNSKA TRANSPARENTNOST

Kao uvod u bolje razumijevanje rada, za početak se definira proračunska transparentnost i što na nju utječe. Sukladno Ministarstvu uprave Republike Hrvatske navode se obilježja i broj jedinica lokalne samouprave te gradova [24].

2.1. Definicija pojmova transparentnosti i proračunske transparentnosti

Teško je pronaći jedinstvenu mjeru koja bi ju savršeno predstavljala, pa ni sama definicija pojma transparentnosti nije jedinstvena. U nastavku se daje pregled nekoliko definicija transparentnosti.

Uz nekoliko iznimaka, prisustvo transparentnosti u raznim dokumentima počinje 1990-ih godina prilikom stvaranja Europske unije [14]. Organizacija *Transparency International* (TI) jedna je od prvih koja se zajedno s *Organizacijom američkih država* (OAS) borila protiv korupcije i zalagala za transparentnost [6]. Iako se na konvenciji iz 1994. nije spominjala riječ "transparentnost", bila je preteča dodatnim forumima i konferencijama OAS-a na kojima se transparentnost počela redovito upotrebljavati zajedno s "odgovornošću" i "dobrim upravljanjem" [9].

Transparentnost u poslovnom ili upravljačkom kontekstu predstavlja iskrenost i otvorenost. Odgovornost i transparentnost općenito se smatraju glavnim stupovima dobrog korporativnog upravljanja [1] i međusobno su povezane. Transparentnost potiče odgovornost, a odgovornost zahtjeva transparentnost. Jedna ne može postojati bez druge, jer su međusobno komplementarne [35].

Proširenjem definicije općenitog pojma transparentnosti, definira se pojam proračunske i fiskalne transparentnosti. U literaturi se često pojmovi proračunske i fiskalne transparentnosti isprepliću i koriste kao sinonim, stoga je teško u potpunosti napraviti jasnu razliku između ta dva pojma. U pregledu literature iz tog se razloga koriste oba pojma.

Kako je sve veća potreba da tijela u javnom sektoru budu transparentnija u informiranju javnosti, nameće se jedna od definicija fiskalne transparentnosti. Prema njoj bi svaka vlada svoje fiskalne aktivnosti trebala otvoreno i pravodobno prezentirati široj javnosti te davati sve važne potpune fiskalne informacije na sustavan način [30].
Sličnu definiciju daju Alt, Lassen i Rose. Prema navedenim autorima pojam fiskalne transparentnosti se odnosi na otvorenost vladinih aktivnosti prema javnosti, dok se proračunska transparentnost odnosi na opću razinu informiranosti građana i medija o vladinim aktivnostima kao i njihovim rezultatima [2].

Najčešće korištenu definiciju proračunske transparentnosti koristi i Organizacija za ekonomsku suradnju i razvoj (OECD, eng. *Organisation for Economic Cooperation and Development*), a ona kaže da transparentnost proračuna možemo ukratko opisati kao potpuno i pravodobno objavljivanje svih važnih vjerodostojnih fiskalnih informacija na sustavan način [27].
Međunarodni monetarni fond (MMF) je proračunsku transparentnost definirao kao sveobuhvatno, razumljivo, pouzdano, pravovremeno i primjenjivo vladino izvještavanje javnosti o prošlim, sadašnjim i budućim fiskalnim aktivnostima te o strukturi i funkcijama vlade koje određuju mjere fiskalne politike i njihove ishode [19].

Veliki pritisak javnosti, naveo je vlade da nakon krize 2008. vode odgovorniju politiku. Kako su se proračunske odluke donosile bez prisustva javnosti, zanemarivale su se potrebe običnih ljudi, odnosno birača. Počelo se pridavati sve više pažnje sudjelovanju građana u procesu kreiranja proračuna kako bi se što

učinkovitije prikupljala i trošila javna sredstva. Danas je jedan od najboljih pokretača i povećanja razine transparentnosti internet. Pristup internetu na kojem se nalaze velike količine svakojakih podataka danas je u svijetu omogućen brojnom stanovništvu. Svaki zainteresirani pojedinac putem interneta vrlo lako, brzo i jednostavno može doći do proračunskih dokumenata što nas dovodi do nove definicije proračunske transparentnosti koju ćemo dalje koristiti u ovom radu.
Ott, Bronić, Petrušić i Stanić [29] proračunsku transparentnost lokalnih jedinica definiraju kao mogućnost građana da na službenim mrežnim stranicama lokalnih jedinica dobiju uvid u potpune, točne i pravovremene proračunske informacije prezentirane na razumljiv način.

Možemo zaključiti kako unatoč velikom broju definicija proračunske transparentnosti, ipak postoji jedna zajednička misao vodilja pri njezinom definiranju. U osnovi svih definicija je ideja da vlada mora objavljivati pravovremene, točne, razumljive i pouzdane informacije. No nije dovoljno samo objavljivati informacije kako bi se proračunska transparentnost povećala, već je važno da građanstvo bude aktivni sudionik procesa.

2.2. Teorijski pristup

Proračunska transparentnost vrlo je važna za razumijevanje političkih odluka i dobivanje pravovremenih informacija o proračunu. Što je više informacija dostupno, bolje se mogu pratiti i nadzirati događaji značajni za ekonomsku sigurnost ljudi. Transparentnost promiče odgovornost Vlade i pruža građanima informacije o tome što ona radi te na taj način ograničava mogućnost pojavljivanja korupcije, ali i jača dobro upravljanje [5], [20]. Također, većom razinom proračunske transparentnosti smanjuje se nepovjerenje prema vladi i njezinim aktivnostima te se više može saznati o politici financiranja unutar gradova [13, 20].

OECD je na temelju iskustva zemalja članica sastavio smjernice za dobru praksu fiskalne transparentnosti koje se odnose na središnju vlast, ali ne i na lokalne jedinice [28].

MMF također objavljuje smjernice za fiskalnu transparentnost te na temelju tih smjernica objavljuje izvješća o fiskalnoj transparentnosti za pojedine zemlje [18]. Ta su načela niti vodilje prema otvorenoj fiskalnoj politici te se često uzimaju kao polazište prilikom izrade upitnika za mjerenje proračunske transparentnosti.

Kako je teško odrediti univerzalnu definiciju proračunske transparentnosti, pojavljuje se i problem njezine mjerljivosti. Ne postoji jedistven i precizan način mjerenja proračunske transparentnosti, ali su smjernice koje daju OECD i MMF ponukale brojne istraživače na izradu upitnika i anketa kao pomoć u osmišljavanju i mjerenju indeksa transparentnosti proračuna.

Primjerice, na MMF-ovom Kodeksu dobre prakse fiskalne transparentnosti temelji se upitnik za istraživanje odrednica lokalnih vlasti galicijskih općina koje su proveli Caamaño-Alegre i njegovi suradnici. [8]

Također, ubrzo nakon što su OECD i MMF objavili smjernice, Alt, Lassen i Rose 2005. objavili su jedno od najistaknutijih i najutjecajnijih studija o uzrocima fiskalne transparentnosti [2]. Ispitivali su odrednice proračunske transparentnosti u SAD-u u razdoblju 1972.-1999. Njihova mjera transparentnosti nije se temeljila na dostupnosti fiskalnih dokumenata, već na transparentnosti državnih proračunskih postupaka. Analizirali su utjecaj političke kompetencije, polarizacije i javnog duga na fiskalnu transparentnost [2].

Međutim, brzim širenjem interneta sve su novije studije uglavnom temeljene na ispitivanju proračunske transparentnosti putem objavljenih dokumenata na službenim mrežnim stanicama. Novije studije proračunsku transparentnost proučavaju u manjim vremenskim razdobljima ili u jednom određenom trenutku.

Tako Guillamon i suradnici [13] kreiraju indeks transparentnosti definiran pomoću podataka dostupnih na stranicama Transparency Internationala (TI) Spain iz 2008. i odgovora na upitnik koji obuhvaća informacije o financijskoj transparentnosti. Upitnik je bio poslan na adrese sto najvećih španjolskih lokalnih jedinica, a sadržavao je dvadeset pitanja o financijskoj transparentnosti. Pitanja su bila

podjeljena u tri grupe: računovodstvo i proračun, transparentnost prihoda i troškova te transparentnost dugova, a sadržavala su informacije o objavljivanju pojedinog dokumenta na lokalnim mrežnim stranicama te stranicama TI. Bilo je moguće osvojiti maksimalno dva boda ovisno o tome jesu li na traženim mrežnim stranicama bili objavljeni pojedini dokumenti te je na temelju toga kreiran indeks. Ispitivali su utjecaj političkih ideologija, broja stanovnika i drugih varijabli na financijsku transparentnost.

Ma i Wu [21] pak kreiraju indeks fiskalne transparentnosti u ovisnosti o ekonomskoj otvorenosti te uravnoteženosti proračuna koji se temelji na 113 pitanja postavljenih kineskim provinciama, od kojih su se 66 odnosila na izvještaj provincijskih vlada, 30 na izvještaj o socijalnom osiguranju te 17 na poduzeća u provincijskom vlasništvu.

Nadalje, u Španjolskoj su Serrano- Cinca i suradnici [32] za procjenu proračunske transparentnosti koristili indeks dobiven mjerenjem proračunske transparetnosti brojem ključnih proračunskih dokumenata objavljenih na službenim mrežnim stranicama lokalnih vlasti. Indeks se kreće u rasponu od 0 do 9, gdje 0 označava da nijedan proračunski dokument nije objavljen, dok 9 označava da je svih 9 traženih dokumenata objavljeno na službenim stranicama.

Proučavanje transparentnosti potaknuto je ciljevima normativne politike dobrog upravljanja i pripadajućim metodama i konceptualnim pretpostavkama. U literaturi o razvojnim studijama transparentnost se prvenstveno vidi kao instrument odgovornosti usred zabrinutosti zbog neučinkovitosti vlade [5,7].

Većina se autora danas orijentira na transparentnost podataka objavljenih na službenim mrežnim stranicama. Dok jedni transparentnost mjere uključujući potpunost, pravovremenost i pristupačnost informacija, drugi se baziraju samo na dostupnosti informacija. Iz danih primjera možemo zaključiti da zbog nepostojanja jedinstvene definicije proračunske transparentnosti ne postoji niti jedinstveni način njezinog mjerenja. Različiti autori koriste različite podatke kako bi procijenili transparentnost zemalja ili njihovih lokalnih jedinica, pa postoje i različiti indeksi proračunske transparentnosti.

2.3. Proračunska transparentnost u RH

Kao mjeru za procjenu razine proračunske transparentnosti u RH, IJF koristi Open Local Budget Index (OLBI). OLBI je zavisna varijabla dobivena mjerenjem proračunske transparentnosti brojem ključnih proračunskih dokumenata objavljenih na službenim mrežnim stranicama jedinica lokalne i područne samouprave koja poprima vrijednosti 0-5 [17].
Pet je ključnih dokumenata za određivanje OLBI-ja: izvještaj o godišnjem izvršenju proračuna, izvještaj o polugodišnjem izvršenju proračuna, prijedlog proračuna, izglasani proračun te proračunski vodič za građane. Razina nula označava da nijedan dokument nije objavljen, dok pet označava kako je svih pet traženih dokumenata objavljeno na službenim mrežnim stranicama jedinica lokalne i područne samouprave [17].
Koristeći OLBI procjenjuje se koje odrednice imaju značajan utjecaj na objavljivanje navedenih pet dokumenata, odnosno proračunsku transparentnost.

Istraživanja su pokazala da se razina proračunske transparentnosti s godinama povećava, pa je tako u šest ciklusa istraživanja porasla s 1,8 na 4,1 [17]. Ipak, taj prosjek prikriva popriličnu raznolikost razine proračunske transparentnosti. Daleko najbolje rezultate imaju županije koje su u promatranom ciklusu u prosjeku objavile 4,9 proračunskih dokumenata. Slijede ih gradovi s prosjekom 4,5. Proračunska transparentnost općina s postignutom prosječnom razinom od 4,0 je u porastu, ali i dalje zaostaje za županijama i gradovima [17].

2.4. Jedinice lokalne samouprave u RH

Nastavak rada posvećen je istraživanju proračunske transparentnosti na razini jedinica lokalne samouprave u RH, točnije na razini gradova.

Sukladno Ministarstvu uprave RH jedinice lokalne samouprave predstavljaju općine i gradovi, a jedinice područne, odnosno regionalne, samouprave su županije. Ukupno je 556 jedinica lokalne samouprave i to: 428 općina, 128 gradova [24].
Kako Grad Zagreb ima poseban status grada i županije, tako u RH ima ukupno 576 jedinica lokalne i područne samouprave.

Općine i gradovi, u svom samoupravnom djelokrugu, obavljaju poslove lokalnog značaja kojima se neposredno ostvaruju potrebe građana, a koji nisu Ustavom ili zakonom dodijeljeni državnim tijelima. Županije obavljaju poslove od područnog značaja. Zakonom o lokalnoj i područnoj samoupravi [25] utvrđeno je da u djelokrug općina i gradova ulaze uređenje naselja i stanovanja, prostorno i urbanističko planiranje, komunalno gospodarstvo, briga o djeci, socijalna skrb, primarna zdravstvena zaštita, odgoj i osnovno obrazovanje, kultura, tjelesna kultura i sport, zaštita potrošača, zaštita i unapređenje prirodnog okoliša, protupožarna i civilna zaštita, promet na svome području te ostali poslovi sukladno posebnim zakonom.
Jedinice lokalne i područne samouprave imaju predstavničko i izvršno tijelo koje se bira na neposrednim izborima, tajnim glasovanjem, na mandat od četiri godine. Svaka jedinica lokalne i područne samouprave ima svoj proračun- akt kojim se procjenjuju prihodi i primici te utvrđuju rashodi i izdaci za jednu godinu, u skladu sa zakonom i odlukom donesenom na temelju zakona, a donosi ga njezino predstavničko tijelo [24].

Proračun grada je temeljni financijski akt u kojem su utvrđeni svi prihodi i rashodi jednog grada za proračunsku godinu koja počinje 1.1., a završava 31.12. Predlaže ga gradonačelnik, a donosi Gradsko vijeće s većinom glasova svih članova vijeća [11]. U proračunu svakog grada prikazuju se prihodi i primici koji pripadaju tom gradu, primici i izdaci u vezi s imovinom u vlasništvu grada te izdaci potrebni za poslove iz njegovog samoupravnog djelovanja. Glavna stavka u proračunima svih

gradova su porezi. Uz njih u proračunu se nalaze i neporezni prihodi, kapitalni prihodi te dotacije [16].

Brojna su načela kojih se gradovi moraju pridržavati prilikom sastavljanja proračuna; načelo uravnoteženosti, načelo jedne godine, načelo jedinstva i točnosti, načelo univerzalnosti, načelo specifikacije, načelo transparentnosti i načelo dobrog financijskog upravljanja. Tim načelima predstavnička vlast lakše može kontrolirati i ograničavati izvršnu vlast (gradonačelnika) u prikupljanju sredstava i načinu njihova trošenja. Načelom transparentnosti određeno je da proračun, kao i potpuni polugodišnji i godišnji izvještaj o izvršenju proračuna moraju biti dostupni javnosti jer tako mogu pomoći građanima da razumiju i sudjeluju u odlučivanju o političkim i ekonomskim odlukama koje utječu na njihovu svakodnevicu. Isto tako, mogu povećati kontrolu građana prema vlastima pa samim time i povećati odgovornost vlasti te smanjiti korupciju [12].

2.5. Hipoteze

Odrednice koje utječu na otvorenost proračuna mogu se podijeliti u ekonomsku, političku i socio-kulturološku skupinu. Na uzorku od 128 gradova testira se nekoliko odrednica i postavljaju se iduće hipoteze:

H1: Broj stanovnika grada pozitivno djeluje na proračunsku transparentnost.

Veći gradovi obično raspolažu s više javnih sredstava. Kako koriste više sredstava, od njih se očekuje veća odgovornost u njihovom korištenju istih. Prema istraživanju provedenom na sto najvećih španjolskih općina pokazano je kako broj stanovnika ima pozitivan učinak na razinu transparentnosti lokalne jedinice [13].

H2: Što su prihodi po stanovniku veći, to je veći pozitivan učinak na proračunsku transparentnost.

Prema Guillamónu, Bastidi i Benitu građani žele znati kuda njihov novac odlazi. Ako moraju više trošiti, odnosno plaćati veće poreze (veći prihodi po stanovniku),

tada zahtijevaju veću razinu transparentnosti [13]. Alt, Lassen i Rose smatraju kako prihodi po stanovniku nemaju velikog utjecaja u odnosu na proračunsku transparentnost [2].

H3: Proračunska transparentnost je pozitivno povezana sa suficitom po stanovniku.

Bastida i Benito tvrde kako će političari manje koristiti fiskalne deficite za ostvarivanje vlastitih oportunističkih ciljeva ukoliko postoji više informacija o proračunu [13]. Drugim riječima, što je veći stupanj proračunske transparentnosti, veći je i suficit. Do istih rezultata dolaze i J. Caamaño-Alegre, S. Lago-Peñas, F. Reyes-Santias i A. Santiago-Buobeta tvrdeći da bi se političari željeli pohvaliti odgovornim upravljanjem u slučaju suficita, pa bi tada i razina transparentnosti bila znatno veća [8].

H4: Veći dohodak po stanovniku pozitivno utječe na proračunsku transparentnost.

Građani s većim dohotkom obično imaju veći stupanj obrazovanja i bolji pristup internetu, stoga je logično očekivati kako će tražiti više informacija o učinku vladajućih. Dakle, veći dohodak po stanovniku implicira i bolji pristup internetu te dovodi do veće potražnje za proračunskim dokumentima, a time pozitivno utječe na proračunsku transparentnost. [33]

H5: Proračunska transparentnost negativno je korelirana sa stopom nezaposlenosti.

Potražnja za transparentnošću opada što je ekonomski razvoj lokalne jedinice niži. Niži ekonomski status grada označava i nižu stopu zaposlenosti, odnosno veću stopu nezaposlenosti. Veće stope nezaposlenosti pak štete razini transparentnosti jer smanjuju angažman građana [34].

H6: Rod gradonačelnika pozitivno je povezan s proračunskom transparentnosti.
Zbog sve većih zahtjeva današnjice za rodnom jednakošću, na vodećim pozicijama nalazi se sve više žena. Prema dostupnoj literaturi, koja nije mnogobrojna, povećanje formalnog političkog predstavljanja žena dovodi do rodne raznolikosti, više različitih iskustava i vrijednosti koje se razlikuju od muškaraca. Pretpostavka je kako će veća zastupljenost žena u lokalnom političkom životu povećati transparentnost informacija. [3]

Iz navedenih hipoteza upoznajemo šest različitih varijabli. To su: broj stanovnika, prihodi po stanovniku, suficit po stanovniku, dohodak po stanovniku, stopa nezaposlenosti i rod gradonačelnika. U idućim poglavljima navedene varijable koriste se za konstrukciju modela koji najbolje opisuje indeks proračunske transparentnosti OLBI.
Može se zaključiti da je interes za proučavanjem odrednica koje utječu na proračunsku transparentnost u porastu kako u svijetu tako i u RH. Uz brojnu stranu literaturu postoje i domaći autori koji se bave ovom tematikom. Istraživanja su pokazala kako je razina indeksa OLBI u porastu, ali je proračun hrvatskih jedinica lokalne samouprave nedovoljno transparentan jer hrvatski građani nedovoljno sudjeluju u proračunskom procesu.

Cilj ovog rada je utvrditi varijable koje su povezane s proračunskom transparentnosti 128 hrvatskih gradova. Zavisna varijabla je OLBI, a nezavisne varijable su: rod gradonačelnika, prihodi po stanovniku, dohodak po stanovniku, suficit/deficit po stanovniku, stopa nezaposlenosti te broj stanovnika.

3. METODOLOGIJA

U ovom radu koristit će se regresijskim modelom, odnosno statističkom vezom između zavisne varijable OLBI i izabranih nezavisnih varijabli. Najzastupljeniji model za izračun takvih vrsta odnosa je linearna regresija kao krajnje jednostavan i adekvatan alat za izračun linearne povezanosti zavisne i nezavisnih varijabli. S obzirom da ta veza u dosta slučajeva nije linearna, upotrijebit ćemo jednu od podvrsti generaliziranih linearnih modela. Kako je indeks transparentnosti OLBI (zavisna varijabla) obilježen diskretnim nenegativnim vrijednostima, koristit će se Poissonova regresija s ciljem utvrđivanja nezavisnih varijabli koje imaju pozitivan ili negativan utjecaj na razinu transparentnosti i kolika je točna razina utjecaja određene nezavisne varijable na OLBI. Kako bi se utvrdilo koliko je određeni model prilagođen stvarnim podacima, u praksi se upotrebljavaju Pearsonov test i test devijance.

Ovo poglavlje daje uvid u teorijski okvir, definiciju i svojstva generaliziranih linearnih modela općenito [4]. Također, u ovom poglavlju se metodom maksimalne vjerodostojnosti računa procjenitelj maksimalne vjerodostojnosti [31], te se upoznaje s Poissonovom distribucijom i Poissonovom regresijom [26].

3.1. Generalizirani linearni modeli

Slovom Y se označava zavisna slučajna varijabla, a sa $X = (x_1, x_2, x_3, \ldots, x_n)$ vektor nezavisnih slučajnih varijabli. Ukoliko se radi o više nezavisnih događaja, podaci se zapisujuo kao niz uređenih parova (y_i, x_i), $i = 1, \ldots, n$. Vrijednost zavisne varijable Y označavaju se sa y_i, a vrijednosti svih nezavisnih varijabli $(x_1, x_2, x_3, \ldots, x_n)$ koje se odnose na y_i označavaju se sa x_i, tj. kaže se da je y_i realizacija slučajne varijable Y_i čija razdioba ovisi o kovarijatama x_i. Cilj je pronaći model koji će za danu vrijednost $x_1, x_2, x_3, \ldots, x_n$ procijeniti vrijednost za y_i tako da pogreška bude čim manja.

Jedan od najpoznatijih modela koji može dati odgovor zadanog problema je linearna regresija.

Kod jednostavne linearne regresije pretpostavka je da slučajna varijabla Y_i na linearan način ovisi o numeričkoj kovarijati x_i:

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_n x_n + \varepsilon$$

pri čemu su $\beta_0, \beta_1, \ldots, \beta_n$ koeficijenti modela koji se procjenjuju, ε slučajna pogreška iz $N(0, \sigma^2)$, a komponente od Y nezavisno distribuirane s konstantnom varijancom. Pretpostavka linearnog modela je da postoji linearna veza između očekivanja zavisne i nezavisnih varijabli. Uz pretpostavku da su prediktorske varijable međusobno nezavisne te da ih ima *k*, slijedi:

$$\mu = E[Y_i] = \sum_{j=1}^{k} \beta_i x_{ij} \qquad (1)$$

Drugim riječima, komponente slučajne varijable Y su međusobno nezavisne s očekivanjem μ i konstantnom varijancom, a veza između Y i njezinih kovarijata zapuje se kao $\mu = \omega$, pri čemu je $\omega = \sum_{j=1}^{k} \beta_i x_{ij}$.

Može se zapisati $\omega = g(\mu)$, pri čemu funkciju g nazivamo funkcija veze. U slučaju linearne regresije radi se o funkciji identiteta.

Proširenjem običnog linearnog modela tako da Y_i ima unaprijed određenu razdiobu iz eksponencijalne familije razdioba, a funkcija veze može biti bilo koja monotona diferencijabilna funkcija, dobije se skupinu generaliziranih linearnih modela.

Generalizirani linearni modeli su proširenje običnih linearnih s pretpostavkom da vrijedi sljedeće:

$$E[Y_i] = g^{-1(\sum_{j=1}^{k} \beta_i x_{ij})} \qquad (2)$$

gdje je g^{-1} inverz funkcije veze g, $\sum_{j=1}^{k} \beta_i x_{ij}$ linearni prediktor, a zadano očekivanje Y_i ima unaprijed određenu razdiobu iz eksponencijalne familije. Iako iz teorijskih razloga slučajna komponenta odziva mora imati razdiobu iz neke od eksponencijalnih familija, ova restrikcija u praksi je prihvatljiva jer eksponencijalne familije uključuju sve najčešće korištene razdiobe.

Za slučajnu varijablu se kaže da pripada nekoj eksponencijalnoj familiji ako joj gustoća (neprekidna ili diskretna) ima oblik:

$$f(y;\ \theta, \varphi) = e^{\frac{y\theta - b(\theta)}{a\,(\varphi)} + c\,(y,\varphi)} \qquad (3)$$

za neke funkcije a, b i c. Parametar θ naziva se prirodni parametar, a φ parametar disperzije ili skaliranja.

Promotrimo funkciju log-vjerodostojnosti unutar neke eksponencijalne familije:

$$l(y; \theta, \varphi) = \log(f(y; \theta, \varphi)) \qquad (4)$$

Postoje dva rezultata koja su poznata iz statističke teorije:

$$E\left[\frac{\partial l}{\partial \theta}\right] = 0\ i\ E\ \left[\frac{\partial^2 l}{\partial \theta^2}\right] + E\left[\left(\frac{\partial l}{\partial \theta}\right)^2\right] = 0 \qquad (5)$$

Za log-vjerodostojnost unutar eksponencijalnih familija iz (3) i (4) vrijedi:

$$\frac{\partial l}{\partial \theta} = \frac{y - b'(\theta)}{a\,(\varphi)} \qquad (6)$$

Upravo zato iz (5) slijedi kako očekivanje od *Y* ovisi samo o prirodnom parametru:

$$\mu = E[Y] = b'(\theta) \leftrightarrow \theta = b'^{-1}(\mu). \qquad (7)$$

Iz (3) i (4) također vrijedi:

$$\frac{\partial^2 l}{\partial \theta^2} = \frac{-(\theta)}{a(\varphi)} \qquad (8)$$

te iz (5) dobijemo sljedeće:

$$Var(Y) = a(\varphi)^2 E\left(\frac{Y-b'(\theta)}{a(\varphi)}\right)^2 = a(\varphi)^2 E\left[\left(\frac{\partial l}{\partial \theta}\right)^2\right] = -a(\varphi)^2 E\left[\frac{\partial^2 l}{\partial \theta^2 = a(\varphi\varphi)b''(\theta}\right] \qquad (9)$$

Iz priloženog se vidi kako varijanca ovisi o oba parametra, a očekivanje samo o parametru θ.

3.2. Poissonova regresija

U ovom poglavlju fokus će biti na Poissonovoj regresiji koja je jedan od modela iz skupine generaliziranih linearnih modela. Kao što se može naslutiti iz prethodnog poglavlja, komponente Y_i zavisne varijable Y su međusobno nezavisne i imaju Poissonovu distribuciju koja pripada eksponencijalnoj familiji.

Za slučajnu varijablu Y kažemo da ima Poissonovu razdiobu s parametrom μ i pišemo $Y \sim Poiss(\mu)$, ako za $\mu > 0$ poprima cjelobrojne vrijednosti *y = 0,1,2,3,4,…* s vjerojatnosti:

$$P(Y = y) = e^{-\mu}\frac{\mu^y}{y!} \qquad (10)$$

Poznato je da je Poissonova regresija oblik generaliziranog linearnog modela koji se koristi kada zavisna varijabla poprima nenegativne diskretne brojeve.

Iz (3) i (10) sijedi:

$$f_y(y;\theta,\varphi) = \frac{\mu^y e^{-\mu}}{y!} = e^{[y\log\mu - \mu - logy!]} \qquad (11)$$

Iz gornje jednakosti se iščitava:

$$\theta = \log\mu$$

$$\varphi = 1, \qquad zato\ je\ a(\varphi) = 1$$

$$b(\theta) = e^{\theta}$$

$$c(y, \varphi) = -logy!$$

Dakle, $log\mu$ je prirodni parametar Poissonove distribucije. Očekivanje slučajne varijable s Poissonovom distribucijom je $E[Y] = b'(\theta) = e^{\theta} = \mu$.
Očekivanje od Y je funkcija linearnog predviditelja $\omega = \beta_1 x_1 +, \dots, \beta_n x_n$ oblika $b'^{\circ}h$ za neke funkcije $\theta = h(\omega)\ i\ \mu = b'(\theta) = b'(h(\omega))$.
Slijedi $\mu = g^{-1}(\omega)$, odnosno $\omega = g(\mu)$, za funkciju $g = h^{-1^{\circ}} b'^{-1}$, koja se naziva funkcija veze i koja povezuje linearni predviditelj s očekivanom vrijednosti. Ukoliko je $h \equiv id$, slijedi da je $\theta = b'^{-1}$, a $g = b'^{-1}$. Upravo zato vrijedi $g(\mu) = log\mu$. Logaritamska funkcija je dobar izbor s obzirom da smo tražili funkciju veze koja omogućava da nezavisne slučajne varijable budu iz cijelog skupa relanih brojeva ***R*** te da μ prima samo nenegativne vrijednosti.

Funkcija varijance dana je s: $Var(\mu) = 1 * b''(\theta) = e^{\theta} = \mu$.
Dakle, kako je $a(\varphi) = 1$ zaključujemo da je varijanca proporcionalna očekivanju.

Iz Poissonove distribucije izveden je Poissonov regresijski model uz pretpostavku da parametar μ ovisi o nezavisnim varijablama. Ta se ovisnost zapisuje jednadžbom:

$$E[y_i|x_i] = \mu_i = e^{x_i^T \beta} = e^{\beta_0 + \beta_1 * x_1 + \beta_2 * x_2 +, \dots + \beta_n * x_n} = Var\ (y_i|x_i) \qquad (12)$$

Glavni uvjet Poissonove regresije je svojstvo ekvidisperzije koje označava jednakost uvjetnog očekivanja i uvjetne varijance. Podaci su previše raspršeni, ako ne vrijedi jednakost već $E[y_i|x_i] < Var\ (y_i|x_i)$. Tada su procijenjeni koeficijenti točni, ali kako standardne greške nisu iste ni p-vrijednosti nisu iste, pa model treba bolje prilagoditi podacima. Za provedbu provjere svojstva ekvidisperzije koristi se test disperzije.

Prilikom vršenja istraživanja varijanca je uglavnom veća od očekivanja. Nakon odabira odgovarajućeg modela potrebno je procijeniti njegove parametre. Procjena parametara modela nije jednostavna. Kako bismo pronašli procijenjene parametre *β* koristit ćemo metodu maksimalne vjerodostojnosti.

3.3. Metoda maksimalne vjerodostojnosti

Neka je *(x_1, x_2, x_3, ….x_n)* opaženi uzorak za varijablu *X* s gustoćom $f(x|\beta)$ pri čemu je $\beta = (\beta_1, \beta_2, \dots., \beta_q) \in R^q$ nepoznati parametar. Funkcija vjerodostojnosti $L: \Omega \rightarrow R$ definira se na idući način: $L(\beta) = f(x_1|\beta) * f(x_2|\beta) * \dots * f(x_n|\beta),\ \beta \epsilon\ \Omega$.
Vrijednost $\hat{\beta} = \hat{\beta}(x_1, x_2, x_{3,\dots,} x_n) \in \Omega$ za koju je:

$$L(\hat{\beta}) = \max_{\beta \epsilon \Omega} L\ (\beta) \qquad (13)$$

se naziva procjena metodom maksimalne vjerodostojnosti. $\hat{\beta}$ se naziva procjeniteljem maksimalne vjerodostojnosti.
Nadalje, potrebno je pronaći funkciju log- vjerodostojnosti za Poissonovu razdiobu:

$$l(\beta) = log[L(\beta)] = log \prod_{k=1}^{n} f\ (y_k|x_k, \beta) \sum_{k=1}^{n} \log(f(y_k|x_k, \beta)$$

$$\log(f(y_k|x_k, \beta) = \log\left(\frac{e^{\mu_k} * \mu_k{}^{y_k}}{y_k!}\right) = \log(e^{-\mu_k} * \mu_k{}^{y_k}) - \log(y_k!)$$

$$= -\mu_k + y_k * \log(\mu_{ki}) - \log(y_k!) = y_k x_k^T \beta - e^{x_K^T * \beta} - log(y_k!)$$

$$l(\beta) = \sum_{k=1}^{n} (\ y_k x_k^T \beta - e^{x_k^T * \beta} - log(y_k!)) \qquad (14)$$

Kako je funkcija $\mathrm{f(x)} = \log(x)$ monotona, maksimum vjerodostojnosti će se postići u istim točkama kao i maksimum log-vjerodostojnosti. Iz sume možemo izbaciti $-log(y_k!)$ jer ne sadrži β pa neće imati utjecaja na rezultat.
Procjenitelj maksimalne vjerodostojnosti $\hat{\beta}$ računa se iz uvjeta koji slijedi deriviranjem funkcije log-vjerodostojnosti po β:

$$\sum_{k=1}^{n}\left(y_k - e^{x_k{}^T * \beta}\right) * x_k = 0 \qquad (15)$$

Newton-Raphsonova iterativna metoda je jedna od najčešće korištenih metoda računanja procjenitelja gdje se procijenjeni parametri β mogu zapisati kao vektor $\beta = (\beta_1, \beta_2, \beta_3, \ldots, \beta_n)$. Procjenitelji maksimalne vjerodostojnosti dobiju se iterativnim metodama s obzirom da ih je vrlo teško egzaktno računati.
Iz tvrdnje:

$$Y_1, Y_2\, nezavisne, Y_i \sim Poiss(\mu_i), za\ i = 1,2 \quad Y_1 + Y_2 \sim Poiss(\mu_1 + \mu_2) \qquad (16)$$

slijedi kako se ovisno o predznaku uvjetno očekivanje $\boldsymbol{E}[y_i|\boldsymbol{x}_i]$ povećava ili smanjuje. Prilikom promjene k-te varijable x_k uz sve ostale varijable nepromijenjene, uvjetno očekivanje $\boldsymbol{E}[y_i|\boldsymbol{x}_i]$ se povećava ako je predznak pozitivan, odnosno smanjuje ukoliko je predznak negativan.

3.4. Testovi prilagodbe modela

U cilju utvrđivanja kvalitete samih modela, potrebno je koristiti mjere za njihovu ocjenu. Za provjeru koliko su dani modeli prilagođeni stvarnim podacima koriste se dva testa prilagodbe modela: Pearsonov test i test devijance. Reziduali se koriste kao mjera koliko zadani model dobro leži uz dane podatke, tj. za mjerenje razlike očekivanih od pravih vrijednosti. Devijanca se definira kao mjera odstupanja opažene od očekivane vrijednosti koja je zadana modelom. Kada je u pitanju regresijski model, onda je bitno spomenuti kako on devijancu uspoređuje

sa zasićenim modelom. Prilikom usporedbe procijenjenog sa zasićenim modelom, dobije se informacija koliko je zapravo procijenjeni model dobar.
Zato je devijanca definirana na sljedeći način:

$$D = 2[l(zas, y) - l(pro; y)] \qquad (17)$$

U ovom slučaju $l(zas, y)$ se odnosi na maksimiziranu log-vjerodostojnost zasićenog modela, a $l(pro; y)$ se odnosi na maksimiziranu log-vjerodostojnost procijenjenog modela. Sljedeća formula se koristi za računanje reziduala u Poissonovoj regresiji:

$$r_i = sign(y_i - \hat{\mu}_i) * \sqrt{2\left[y_i * \ln\frac{y_i}{\hat{\mu}_i} - (y_i - \hat{\mu}_i)\right]}, i = 1, \dots, n \qquad (18)$$

Kada je zadovoljen uvjet $\beta = \hat{\beta}$ procijenjeno očekivanje $\hat{\mu}_i$ jednako je uvjetnom očekivanju μ_i. Devijanca se može zapisati i pomoću reziduala na idući način:

$$D = \sum r_i^2 \qquad (19)$$

Neka je *n* broj parametara koji se nalaze u zasićenom modelu, a *q* je broj parametara koji se nalaze u procijenjenom modelu. Ukoliko vrijedi da je devijanca iz X^2 razdiobe uz parametar $n - q$, tada procijenjeni model opisuje stvarne podatke.

$$D \sim X^2_{n-q} \qquad (20)$$

Akaike informacijski kriterij (AIC) koristi se za usporedbu više regresijskih modela. Prema tom kriteriju najbolji model je onaj koji ima najnižu vrijednost. Kako se AIC smanjuje smanjenjem broja parametara ne mora nužno biti točno kako je najbolji onaj model koji ima najnižu AIC vrijednost. Tvrdnja slijedi iz formule:

$$AIC = 2q - 2l(zas; y) \qquad (21)$$

Broj procijenjenih parametara se označava sa q uključujući i slobodni član, a $l(zas; y)$ je funkcija log-vjerodostojnosti zasićenog modela.

3.5. Automatizirane funkcije

Automatizirane funkcije primijenjene u raznim softverskim programima koriste se za odabir najboljeg modela prema nekom odabranom kriteriju. Funkcije su zasnovane na prethodno spomenutom AIC i sličnim kriterijima (BIC, Schwartzov kriterij – SBIC,…).

Kada postoji veliki broj parametara, funkcije koriste razne metode kako ne bi morale prolaziti kroz sve kombinacije. Bitno je reći kako svi ovi algoritmi funkcioniraju iterativno. Regresija najboljeg podskupa (eng. *best subset regression*) jedna je od takvih metoda koja odabire najbolji model od svih mogućih podskupova prema nekom od kriterija prikladnosti modela.

Uobičajeno je koristiti odabir unaprijed (eng. *forward selection*), unatrag (eng. *backward elimination*) i korak po korak (eng. *stepwise regression*). Metoda unaprijed započinje modelom koji je prazan, a zatim se u svakoj fazi dodaje najbolja neizabrana kovarijata sve dok takvih kandidata ne ponestane. Kod metode unatrag, kreće se sa zasićenim modelom te se redom izbacuju kovarijate koje nisu potrebne. Metoda završava kad su ostale samo one varijable koje su od značaja za model. Kombinacija gornje dvije metode se zove korak po korak te je ona najkorisnija kada postoji veliki broj varijabli. Ukoliko više varijabli ima slično značenje stepwise regresija izbacuje one varijable koje se preklapaju s drugima kombinirajući selekciju unaprijed i eliminaciju unatrag sve dok nijedna ne mijenja model. Potrebno je dosta opreza u radu s automatiziranim funkcijama. One su jedna od najboljih provjera ručno izrađenog modela, ali ne smiju biti zamjena za pažljivo razmatranje modela.

U ovom poglavlju upoznaje se s generaliziranim linearnim modelima. Oni poopćuju linearne modele dopuštajući da razdioba slučajnih komponenti dolazi iz bilo koje razdiobe koja pripada razdiobama eksponencijalnih familija te da funkcija veze može biti bilo koja diferencijabilna monotona funkcija. Eksponencijalnim familijama pripadaju brojne često korištene razdiobe, pa GLM-i imaju vrlo široku primjenu u praksi. Jedna od njih je i Poissonova razdioba. Kako je predmet zanimanja u ovom radu OLBI, a on poprima diskretne nenegativne vrijednosti, u nastavku rada koristit ćemo baš Poissonovu regresiju kao vrstu GLM-a prilikom izrade modela s ciljem utvrđivanja utjecaja odabranih nezavisnih varijabli na OLBI.

4. PODACI

Ovo poglavlje pruža pregled svih podataka koji su se koristili u istraživanju. Tema je analizirati varijable koje bi mogle određivati razinu proračunske transparentnosti gradova u RH. Kao zavisna varijabla koristi se indeks OLBI. Predstavljene su i nezavisne varijable odabrane na temelju ranije postavljenih hipoteza.

4.1. Zavisna varijabla

Podaci korišteni u ovom radu su iz istraživanja proračunske transparentnosti gradova, općina i županija u RH, provedenog u razdoblju studeni 2019.- travanj 2020 [17]. Istraživanje se baziralo na činjenici jesu li gradovi objavili izvještaj o godišnjem izvršenju proračuna za 2018, polugodišnjem izvršenju proračuna za 2019., prijedlog proračuna za 2020., izglasani proračun za 2020. i proračunski vodič za građane za 2020.

U obzir su uzeti samo dokumenti koji su se na mrežnim stranicama lokalnih jedinica nalazili u navedenim razdobljima istraživanja i to na dan pretraživanja njihove stranice.

Pravovremenost je jedna od odrednica transparentnosti bez koje građani nisu u stanju sudjelovati u proračunskom procesu, a objava svih pet proračunskih dokumenata na mrežnim stranicama predstavlja potvrdu da se gradovi pridržavaju Zakona o proračunu, Zakona o pravu na pristup informacijama i preporuka Ministarstva financija i nužan je preduvjet za značajnije sudjelovanje građana u odlučivanju o pribavljanju i utrošku sredstava kojima upravlja grad.

Na slici 4.1. nalazi se grafički prikaz razina transparentnosti svih lokalnih jedinica na području RH za 2020.

Slika 4.1. Razina transparentnosti proračuna lokalnih jedinica u Hrvatskoj za 2020.

Izvor: [15] Institut za javne financije, Karta gradova i općina,

http://www.ijf.hr/transparentnost/gradovi/

Na mrežnim stranicama IJF-a [15] moguće je pronaći sve podatke o proračunskoj transparentnosti lokalnih jedinica, odnosno svakog grada i općine zasebno. Dostupni su podaci o tome koliko je i kojih dokumenata pojedina jedinica objavila, a objavljeni dokumenti se mogu i otvoriti.

Grafikon 4.1. Razina transparentnosti 2018.-2020.

Izvor: Izrada autora

Grafikon 4.1. prikazuje kako gradovi iz godine u godinu objavljuju sve više dokumenata, a u 2020. rast objave dokumenata praktički je eksponencijalan.

Grafikon 4.2. je histogram koji prikazuje razinu indeksa OLBI u 2020. Čak 87 gradova je objavilo svih 5 traženih dokumenata, a nema grada koji nije objavio niti jedan traženi dokument, dok je samo jedan s objavljenim jednim dokumentom.

Grafikon 4.2. Histogram varijable OLBI

Izvor: Izrada autora

Uvidom u aritmetičku sredinu svih gradova, prosječna transparentnost gradova je vrlo dobra, odnosno iznosi 4,5.

Grafikon 4.3. pokazuje kako su županije objavljivale najveći broj dokumenata. Gradovi za županijama zaostaju, ali su bolji od općina.

Što se tiče lokalnih jedinica, čak 55% ih je objavilo jednaki broj dokumenata u usporedbi s prethodnim ciklusom. Ipak, 17% jedinica objavilo je manji broj dokumenata nego ranije. Ohrabruje što je oko 40% lokalnih jedinica zadržalo najvišu razinu transparentnosti, a oko 30% ih je objavilo više dokumenata nego u prethodnom ciklusu [17].

Među gradovima se posebno ističu Otok koji je s jedinice skočio na peticu te Pag koji je s dvojke skočio na peticu. Križevci su pak s druge strane jedini grad koji je objavio samo jedan dokument i s četvorke iz prošlog ciklusa pao na jedinicu. Pored Križevaca još je 13 gradova koji su pali na nižu razinu transparentnosti u odnosu

na prošlo razdoblje (Hrvatska Kostajnica, Senj, Trilj, Kutjevo, Opuzen, Orahovica, Vinkovci, Vrlika, Županja, Čazma, Donja Stubica, Kraljevica, Petrinja).

Grafikon 4.3. Objavljeni proračunski dokumenti (u %)

Izvor: [17] Institut za javne financije, Proračunska transparentnost županija, gradova i općina: studeni 2019. – travanj 2020.

https://www.udruga-gradova.hr/wordpress/wp-content/uploads/2020/07/Prora%C4%8Dunska-transparentnost.pdf

Zaključak je da je razina proračunske transparentnosti u RH svakim idućim ciklusom sve veća, ali mjesta za napredak i dalje ima.

4.2. Nezavisne varijable

Nezavisne se varijable generalno grupiraju u tri glavne skupine: ekonomske, političke i socio-kulturološke.

Prilikom izrade modela koristi se idućih šest nezavisnih varijabli: rod gradonačelnika, ukupne prihode po stanovniku, dohodak po stanovniku, procjenu broja stanovnika, stopu nezaposlenosti i suficit odnosno deficit po stanovniku.

Dohodak po stanovniku, prihodi po stanovniku, suficit odnosno deficit po stanovniku kao i stopa nezaposlenosti smještaju se u skupinu ekonomskih varijabli, dok su broj stanovnika i rod načelnika socio-kulturološke varijable.

U tablici 4.1. prikazane su korištene nezavisne varijable s oznakama, izvorom podataka te razdobljem kad su podaci prikupljeni.

Oznaka varijable	***Opis***	***Izvor podataka***	***Razdoblje***
rod_grad	Rod gradonačelnika	Državni zavod za statistiku RH [10]	2018.
stanov	Procjena broja stanovnika	Državni zavod za statistiku RH [10]	2017.
prihod	Proračunski prihod po stanovniku	Ministarstvo Financija [22]	2018.
suf_def	Suficit/deficit po stanovniku	Ministarstvo Financija [22]	2018.
st_nez	Stopa nezaposlenosti	Ministarstvo regionalnog razvoja [23]	2018.
dohodak	Po stanovniku (u kunama)	Ministarstvo regionalnog razvoja [23]	2018.

Tablica 4.1. Popis nezavisnih varijabli

Izvor: Izrada autora

Rod gradonačelnika je kategorijska varijabla koja poprima vrijednost 0 ako je na dužnosti gradonačelnik, odnosno 1 ukoliko je na dužnosti gradonačelnica.

Sljedeća je varijabla veličina lokalne jedinice, odnosno broj njezinih stanovnika. Podaci za ovu varijablu prikupljeni su na stranicama DZS-a [10]. Odnose se na procjenu popisa stanovništva prema rodu, po gradovima i općinama iz 2017. godine. Ti su podaci i dalje aktualni, no treba istaknuti da se ukupan broj stanovnika države, pa time i gradova smanjio na što ukazuju i procjene dostupne na stranici DZS-a.

Prosječan dohodak po stanovniku izračunat je kao omjer ukupnog iznosa dohotka kojeg su tijekom jedne kalendarske godine, odnosno jednog poreznog razdoblja ostvarili svi porezni obveznici i fizičke osobe na području lokalne jedinice i broja stanovnika koji žive na području te jedinice za svaku kalendarsku godinu zasebno. Porezni prihodi po stanovniku omjer su ukupnog prihoda od poreza lokalne jedinice i procijenjenog broja stanovnika te jedinice za svaku kalendarsku godinu zasebno. Suficit ili deficit u ukupnim prihodima pokazuju je li neka jedinica ostvarila plus ili minus na svom računu.

Podaci o proračunskim prihodima te suficitu i deficitu po stanovniku uzeti su iz baze podataka na službenoj mrežnoj stranici Ministarstva financija o ostvarenom proračunu za 2018. [22].

Prosječna stopa nezaposlenosti uzima u obzir broj nezaposlenih u odnosu na ukupno radno sposobno stanovništvo.

Ukratko, zavisna varijabla koja se promatra u ovom radu je OLBI. Od brojnih socio-kulturoloških, ekonomskih i političkih varijabli, odabrano ih je šest čiji utjecaj na OLBI se promatra u ovom radu, a to su: broj stanovnika, rod gradonačelnika, prihodi po stanovniku, dohodak po stanovniku, suficit/ deficit po stanovniku te stopa nezaposlenosti.

5. EMPIRIJSKA ANALIZA NA PRIMJERU SVIH HRVATSKIH GRADOVA

U ovom dijelu prikazana su statistička obilježja odabranih varijabli, korelacijska matrica te Poissonova regresija za sve gradove u RH. Upotreba Poissonove regresije uvjetovana je činjenicom da OLBI poprima isključivo nenegativne cjelobrojne vrijednosti. Na ovaj način, nastojalo se odrediti koje od varijabli imaju najveći utjecaj na proračunsku transparentnost. Ispitivanje prikladnosti modela vrši se testiranjem devijance i Pearsonovim testom.

5.1. Statistička obilježja podataka

U tablici 5.1. je prikazana deskriptivna statistika zavisne i nezavisnih varijabli; minimum, aritmetička sredina, medijan, maksimum te varijanca i standardna devijacija svih varijabli koje koristimo u analizi.

VARIJABLA	MIN	AR. SREDINA	MEDIJAN	MAX	VARIJANCA	ST. DEVIJACIJA
OLBI	1	4,52	5	5	0,69	0,83
ROD_GRAD	0	0,10	0	1	0,09	0,30
STANOV	1.489,00	22.848,00	9.465	806.341,00	5.383.330.638,00	73.371,18
DOHODAK	23.587,00	33.553,00	33.032,00	48.921,00	27.969.403,00	5.288,61
SUF_DEF	-6.643,90	85,22	181,54	3.286,66	1.105.572,00	1.051,46
ST_NEZ	2,93	10,91	10,28	27,19	32,22	5,68
PRIHOD	2.405,00	5.401,00	4.822,00	12.031,00	4.899.460,00	2.213,47

Tablica 5.1. Deskriptivna statistika zavisne i nezavisnih varijabli (zaokruženo na dvije decimale)

Izvor: Izrada autora

Nadalje, promatraju se aritmetičke sredine nezavisnih varijabli u odnosu na razinu zavisne varijable indeksa OLBI.

OLBI	0	1	2	3	4	5
ROD_GRAD	0	0,00	0,25	0,10	0,08	0,10
STANOV	0	19.960,00	5.494,25	9.240,50	13.216,81	28.121,68
DOHODAK	0	30.580,66	29.278,93	28.678,06	32.485,41	34.663,38
SUF_DEF	0	4,91	17,14	14,93	11,79	9,96
ST_NEZ	0	412,91	487,88	-441,36	339,70	47,41
PRIHOD	0	3.464,51	5.386,75	4.553,90	5.729,16	5.423,82

Tablica 5.2. Aritmetičke sredine nezavisnih varijabli (zaokruženo na dvije decimale)

Izvor: Izrada autora

Pogledom na tablicu 5.2. i uzimajući u obzir kako ne postoji nijedan grad koji nije objavio nijedan dokument te postoji samo jedan jedini grad koji je objavio jedan dokument vidi se kako aritmetička sredina varijable rod gradonačelnika nema preveliki značaj na razinu indeksa OLBI, jer se aritmetičke sredine kreću nasumično. Isto vrijedi i za aritmetičku sredinu varijable prihoda po stanovniku. Također, aritmetička sredina stope nezaposlenosti i suficita odnosno deficita po stanovniku uglavnom se smanjuje s većim razinama OLBI-ja. Može se pretpostaviti kako su te dvije nezavisne varijable negativno korelirane s povećanjem zavisne varijable OLBI. Kod broja stanovnika vidljiva je pozitivna povezanost, odnosno s većim razinama OLBI-ja, povećava se i aritmetička sredina broja stanovnika.

5.2. Korelacijska matrica

Postavlja se pitanje u kakvom su odnosu pojedine varijable međusobno. Kako bi se ustvrdila veza među varijablama koriste se koeficijenti korelacije. Korelacija je statistički postupak kojim izračunavamo povezanost između dviju varijabli, a njezinu vrijednost brojčano iskazujemo koeficijentom korelacije. Taj koeficijent pokazuje koliko promjena vrijednosti jedne varijable utječe na promjenu vrijednosti druge varijable. Sve koeficijente moguće je iščitati iz korelacijske matrice prikazane u tablici 5.3.:

	OLBI	STANOV	DOHODAK	ST_NEZ	PRIHOD	SUF_DEF
OLBI	1					
STANOV	0,32	1				
DOHODAK	0,34	0,32	1			
ST_NEZ	-0,26	-0,06	-0,60	1		
PRIHOD	0,07	-0,25	0,23	-0,17	1	
SUF_DEF	-0,07	0,05	-0,21	0,03	-0,06	1

Tablica 5.3. Korelacijska matrica

Izvor: Izrada autora

Koeficijent korelacije je realni broj koji poprima vrijednosti u intervalu [-1,1]. Korelacija varijabli je veća što je vrijednost koeficijenata veća. Ukoliko se povećanjem jedne varijable povećava i iznos druge, tada koeficijent korelacije raste prema 1. U slučaju da se smanjenjem jedne varijable smanjuje iznos druge, koeficijent korelacije približava se iznosu -1. Nula označava da je odnos dviju varijabli slučajan, odnosno da korelacija ne postoji.

Ukoliko je koreliranost nezavisnih varijabli velika u pitanje se dovodi preciznost primijenjenog modela. Iz tog se razloga visoko korelirane varijable ne nalaze u istom modelu, odnosno jednu od njih je potrebno izbaciti. Kategorijske varijable ne nalaze se u korelacijskoj tablici jer za njih uobičajena korelacijska analiza nije prikladna. Korištena je Spearmanova korelacija, koja ne iziskuje dodatne pretpostavke o distribuciji podataka niti linearnosti.

Najveći stupanj korelacije, i to negativnog predznaka, imaju varijable dohodak po stanovniku i stopa nezaposlenosti. Intuitivno možemo razumjeti zašto je to tako. Ukoliko je stopa nezaposlenosti visoka, veliki dio građana ima vrlo mali ili nikakav dohodak, stoga vrijedi negativna korelacija.

Također, negativno su korelirani prihod po stanovniku i stopa nezaposlenosti s malim koeficijentom koreliranosti od -0.17 te prihod po stanovniku i broj stanovnika s nešto većim koeficijentom koreliranosti od -0.25.

Zaključak je da su dohodak po stanovniku i prihodi po stanovniku pozitivno korelirani s koeficijentom 0,23. S nešto većim koeficijentom 0,32 pozitivno su

kolerirani dohodak po stanovniku i broj stanovnika. Nadalje, može se iščitati kako varijable prihodi i suficit/deficit po stanovniku te suficit/deficit i stopa nezaposlenosnosti pokazuju skoro pa nikakvu povezanost.
Potrebna je doza opreza kod toga koji podaci se uzimaju u model. Tablica korelacija daje nagovještaj da se visoko korelirane varijable ne bi trebale stavljati zajedno u procijenjeni model.

Ukratko, korelacija implicira da povezane varijable mjere slične stvari. Drugim riječima, ako se u regresijski model uključe visoko korelirane varijable, neke od njih će biti suvišne i nepotrebne, stoga se pomoću koeficijenata korelacije nastoji odrediti koje bi to varijable mogle biti povezane. Takve se varijable tada neće koristiti u istom modelu.

5.3. Jednostruka Poissonova regresija

Cilj Poissonove regresije jest procijeniti parametre modela te odabrati model koji najbolje opisuje podatke uz najmanji mogući broj varijabla. Provođenjem jednostruke Poissonove regresije za svaku od nezavisnih varijabli određuje se statistička značajnost svake varijable posebno. Sve operacije rađene su u programskom jeziku R-u.
Jednostruki model dan je s:

$$E(OLBI) = Exp(\beta_0 + \beta_1 * nezavisna_varijabla)$$

Koristit će se razina značajnosti od 5%, što daje 95% pouzdanost procijene koeficijenata. Drugim riječima na razini značajnosti od 5% pokušat će se utvrditi koje su nezavisne varijable statistički značajne za zavisnu varijablu OLBI. Za parametar β_1 kaže se da je statistički značajan ako se statistički značajno razlikuje od 0.

VARIJABLA	SLOBODNI ČLAN	KOEFICJENT	PROMJENA OLBI-JA (U %)	STANDARDNA GREŠKA	Z VRIJEDNOST	P-VRIJEDNOST*
ROD_GRAD	1,5089	-0,0134	1,3	0,1384	-0,097	0,923
STANOV	1,50	0,00000022	0,00	0,00000053	0,422	0,673
DOHODAK	1,12	0,00001160	0,00	0,00000780	1,488	0,137
SUF_DEF	1,60	-0,00847000	0,84	0,00746200	-1,135	0,256
ST_NEZ	1,51	-0,00000349	0,00	0,00003953	-0,088	0,929
PRIHOD	1,48	0,00000578	0,00	0,00001873	0,308	0,758

Tablica 5.4. Jednostruka Poissonova regresija

Izvor: Izrada autora

Dobivena p-vrijednost koristi se za određivanje značajnosti svakog pojedinog procijenjenog koeficijenta modela, tj. testiraju se sljedeće hipoteze:

$$H_0: \beta_1 = 0$$
$$H_0: \beta_1 \neq 0$$

Niža razina p–vrijednosti od 0,05 signaliza odbacivanje nulhipoteze. Onaj prediktor koji ima nisku p-vrijednost biti će značajan dodatak modelu.

U jednostrukim modelima sve su p-vrijednosti vrlo visoke pa se dolazi do zaključka da varijable nisu statistički značajne.

Promjena OLBI-ja u postocima označava promjenu zavisne varijable u odnosu na povećanje jedne jedinice nezavisne varijable, uz uvjet da su sve ostale varijable nepromijenjene.

Prema predznaku dobivenih koeficijenata može se zaključiti kako varijable stopa nezaposlenosti, deficit/suficit po stanovniku kao i rod gradonačelnika imaju negativan utjecaj na zavisnu varijablu OLBI. No, s obzirom na vrlo visoke razine p-vrijednosti one nemaju statistički značajnog utjecaja na transparentnost.

Nadalje, dohodak po stanovniku, prihodi po stanovniku kao i broj stanovnika imaju pozitivan utjecaj na razinu proračunske transparentnosti. Iako su p-vrijednosti jednostrukih modela s dohotkom po stanovniku i stopom nezaposlenosti puno manje od ostalih (prema tablici 5.4.), ipak su previsoke da bi se na razini

značajnosti od 5% mogla odbaciti nulhipoteza u korist hipoteze o statističkoj značajnosti tih varijabli.

Nakon što je napravljen model, potrebno je utvrditi njegovu kvalitetu.
Promatrati će se odnos null i rezidualnih devijanci. Rezidualne devijance opisuju koliko dobro predloženi model opisuje podatke, dok null devijanca pokazuje koliko dobro osnovni model (dakle, samo slobodni član) opisuje podatke.

VARIJABLA	NULL	RESIDUAL	AIC
ROD_GRAD	22,847	22,837	456,93
STANOV	22,847	22,678	456,77
DOHODAK	22,847	20,651	454,75
ST_NEZ	22,847	21,546	455,64
SUF_DEF	22,847	22,839	456,93
PRIHOD	22,847	22,752	456,85

Tablica 5.5. Pregled devijanci i AIC kriterija za sve zavisne varijable

Izvor: Izrada autora

Iz tablice 5.5. se može zaključiti kako je bolji model onaj s jednom zavisnom varijablom u odnosu na konstantan model jer su sve rezidualne devijance manje od null devijanci.
Također prilikom uspoređivanja modela koristi se i AIC kriterij. Što je AIC manji, to je model prikladniji. Kako svi modeli imaju isti broj parametara, a najmanju rezidualnu devijancu kao i najmanju AIC vrijednost ima varijabla dohodak po stanovniku zaključuje se kako je to model koji najbolje opisuje dane podatke.

5.4. Višestruka Poissonova regresija

Provest će se i višestruka Poissonova regresija. Ona započinje razmatranjem zasićenog modela. Koristit će se ista razina značajnosti od 5% kao i ranije.

Zasićeni model je onaj koji sadrži sve odabrane nezavisne varijable, a dan je s:

$$E(OLBI) = Exp(\beta_0 + \beta_1 * stanov + \beta_2 * st_nez + \beta_3 * dohodak + \beta_4 * prihodi + \beta_5 * suf_def + \beta_6 * rod_grad)$$

Dobivena p-vrijednost koristi se za određivanje značajnosti svakog pojedinog procijenjenog koeficijenta modela, tj. testiraju se sljedeće hipoteze:

$$H_0: \beta_j = 0$$

$$H_0: \beta_j \neq 0$$

Niža razina p–vrijednosti od 5% signalizira odbacivanje nulhipoteze. Onaj prediktor koji ima nisku p-vrijednost biti će značajan dodatak modelu.

	PROCIJENJENI KOEFICIJENT β_i	STANDARDNA GREŠKA	PROMJENA OLBI-JA (U %)	Z VRIJEDNOST	P-VRIJEDNOST
SLOBODNI ČLAN	1,215000000	0,4277000	-	2,842	0,005
ROD_GRAD	-0,000000025	0,0000058	0,000	-0,043	0,966
STANOV	-0,003113000	0,0094500	0,300	-0,329	0,748
DOHODAK	0,000010090	0,0000106	0,001	0,957	0,339
SUF_DEF	-0,003113000	0,0094500	0,300	-0,329	0,894
ST_NEZ	-0.000002616	0,0000197	0,000	-0,133	0,894
PRIHOD	0,003675000	0,1402000	0,300	0,026	0,980

Tablica 5.6. Rezultati Poissonove regresije zasićenog modela

Izvor: Izrada autora

Provedenom regresijom s uključenim svim nezavisnim varijablama u model dolazi se do zaključka kako varijabla slobodni član jedina ima statistički značajan utjecaj na zavisnu varijablu OLBI. Vrlo nizak, ali pozitivan učinak na OLBI imaju dohodak po stanovniku kao i prihod po stanovniku što je u skladu s teorijskim hipotezama, dok ostale varijable imaju negativan utjecaj prema provedenom modelu. Koeficijenti regresije ukazuju na to koliki utjecaj promjena neke nezavisne varijable ima na kretanje zavisne varijable. U ovom su slučaju svi ti utjecaji vrlo mali s

obzirom na male vrijednosti dobivenih koeficijenata. Također, kako su sve p-vrijednosti vrlo visoke njihov utjecaj na OLBI nije statistički značajan.
Null devijanca modela iznosi 22,846 u 127 stupnjeva slobode, dok je rezidualna devijanca 20,520 uz 121 stupanj slobode, a AIC kriterij 464,62.
Na temelju niže vrijednosti rezidualne devijance od vrijednosti null devijance može se zaključiti kako će prediktivno biti bolji onaj model koji sadrži sve varijable u odnosu na model koji sadrži samo slobodan član.

Analizirat će se ovaj model koristeći gotovu funkciju drop1. Drop1 izbacuje jednu po jednu varijablu iz modela sve dok ne dođe do onog koji sa što manjim brojem varijabli najbolje opisuje dane podatke.
Na slici 5.1. moguće je uočiti kako niže vrijednosti AIC kriterija dobivamo u slučaju izbacivanja bilo koje varijable.

```
Model:
OLBI ~ stanov + st_nez + dohodak + prihod + suf_def + rod_grad
         Df Deviance    AIC F value Pr(>F)
<none>        20.520 464.62
stanov    1   20.522 462.62  0.0109 0.9170
st_nez    1   20.629 462.72  0.6408 0.4250
dohodak   1   21.436 463.53  5.4004 0.0218 *
prihod    1   20.538 462.63  0.1047 0.7469
suf_def   1   20.523 462.62  0.0162 0.8988
rod_grad  1   20.521 462.62  0.0040 0.9494
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
```

Slika 5.1. Rezultat funkcije drop1 u programu R

Izvor: Izrada autora

Traži se prikladniji model tako da iz zasićenog modela uklonimo neke varijable. Potrebno se na tren vratiti na ranije prikazanu tablicu korelacije (tablica 5.3.).
Iz nje je vidljivo kako su varijable broj stanovnika i dohodak po stanovniku bile visoko korelirane s prihodima po stanovniku.
Već je ranije naglašeno kako se varijable s većim koeficijentom korelacije kreću slično te se zato ne očekuje da će se one naći u istom modelu. Iz tog razloga

izborom novog modela, izbacujući neke od koreliranih varijabli, trebali bi doći do boljih zaključaka.

Stoga se kreira model 1 kojeg čini puni model iz kojeg se izbacuju varijable dohodak po stanovniku i broj stanovnika zbog visoke korelacije s varijablom prihodi po stanovniku:

$$E(OLBI) = Exp(\beta_0 + \beta_1 * st_nez + \beta_2 * prihodi + \beta_3 * suf_def + \beta_4 * rod_grad).$$

U tablici 5.7. prikazani su rezultati Poissonove regresije za ovaj model.

	PROCIJENJENI KOEFICIJENT β_i	STANDARDNA GREŠKA	PROMJENA OLBI-JA (U %)	Z VRIJEDNOST	P-VRIJEDNOST
SLOBODNI ČLAN	1,59800000	0,15530000	-	10,290	<2e-16***
ST_NEZ	-0,00842800	0,00772200	0,83900	-1,091	0,275
PRIHOD	0,00000076	0,00001933	0,00007	0,009	0,993
SUF_DEF	-0,00000722	0,00003990	0,00017	-0,043	0,966
ROD_GRAD	-0,00835800	0,13960000	0,83232	-0,060	0,952

Tablica 5.7. Rezultati Poissonove regresije modela 1

Izvor: Izrada autora

Pozitivan utjecaj na zavisnu varijablu OLBI ima varijabla prihodi po stanovniku. Na OLBI negativno utječu varijable stopa nezaposlenosti, rod gradonačelnika i suf_def.

U ovom modelu također nije dobivena ni jedna statistički značaja varijabla. Sve nezavisne varijable, osim stope nezaposlenosti imaju izrazito visoku razinu p-vrijednosti. Dakle, ne može se odbaciti nulhipoteza u korist hipoteze da je neka od nezavisnih varijabli statistički značajna za model.

Za varijablu s najmanjom p- vrijednosti, odnosno stopu nezaposlenosti, na temelju dobivenog koeficijenta β_i koji iznosi -0,008428 zaključuje se kako ima negativan utjecaj na odzivnu varijablu OLBI što je u skladu s pretpostavkom kako više stope nezaposlenosti označavaju niži stupanj zaposlenosti kao i usporeni ekonomski razvoj pa samim time i manji angažman građana te njihov interes za potrošnju proračunskih sredstava postaje manji. To bi značilo da u slučaju povećanja stope nezaposlenosti za jednu jedinicu, u slučaju da sve ostale varijable ostanu

nepromijenjene, dolazi do smanjenja očekivane razine OLBI-ja za 0,84%. Kako p-vrijednosti pokazuju da nijedna nezavisna varijabla nema statistički značajan utjecaj na očekivanu razinu transparentnosti, zaključuje se da kretanje zavisne varijable nije usko povezano s promjenama u odabranim varijablama.

Dalje se provodi test omjera vjerodostojnosti za zasićeni puni model i model 1. Njime se uspoređuju dva modela samo ukoliko je jedan model podskup drugoga. Rezultati su dani na slici 5.2.:

```
Model 1: OLBI ~ st_nez + prihod + suf_def + rod_grad
Model 2: OLBI ~ stanov + st_nez + dohodak + prihod + suf_def + rod_grad
  Resid. Df Resid. Dev Df Deviance Pr(>Chi)
1       123      21.54
2       121      20.52  2   1.0191   0.6008
>
```

Slika 5.2. Test omjera vjerodostojnosti za model 1 i zasićeni model

Izvor: Izrada autora

Nulhipoteza je: model 1 je bolji od zasićenog modela. Stoga se na razini značajnosti od 0,05 ne odbacuje nulhipoteza u korist hipoteze da je zasićeni model bolji od modela 1. Drugim riječima, model 1 bolje opisuje dane podatke nego zasićeni model.

Nadalje, kreira se model 2 koristeći isti princip razmišljanja kao kod modela 1.

Iz zasićenog modela izbacuju se varijable broj stanovnika i prihod po stanovniku, jer se pogledom na matricu korelacije 5.3. vidi kako su obje visoko korelirane s varijablom dohodak po stanovniku.

Model 2 dan je s:

$$E(OLBI) = Exp(\beta_0 + \beta_1 * st_nez + \beta_2 * dohodak + \beta_3 * suf_def + \beta_4 * rod_grad).$$

Analizom procijenjenog modela dobiveni su idući rezultati.

	PROCIJENJENI KOEFICIJENT β_i	STANDARDNA GREŠKA	PROMJENA OLBI-JA (U %)	Z VRIJEDNOST	P-VRIJEDNOST
SLOBODNI ČLAN	1,21200000	0,3990000	-	3,037	0,002***
ST_NEZ	-0,00301900	0,0092320	0,301445	-0,327	0,745
DOHODAK	0,00000973	0,0000097	0,000094	1,001	0,312
SUF_DEF	-0,00000183	0,0000404	0,000183	-0,045	0,964
ROD_GRAD	0,00388300	0,1402000	0,389054	0,028	0,978

Tablica 5.8. Rezultati Poissonove regresije modela 2

Izvor: Izrada autora

Tablica 5.8. prikazuje kako pozitivan utjecaj na odzivnu varijablu OLBI ima varijabla dohodak po stanovniku te varijabla rod gradonačelnika. Na OLBI negativno utječu varijable stopa nezaposlenosti i suficit/deficit po stanovniku.

U ovom modelu nije dobena niti jedna statistički značaja varijabla. Sve nezavisne varijable, osim dohotka po stanovniku imaju izrazito visoku razinu p-vrijednosti. Dakle, ne može se odbaciti nulhipoteza u korist hipoteze da je neka od nezavisnih varijabli statistički značajna za model.

Za varijablu s najmanjom p-vrijednosti, odnosno dohodak po stanovniku, se na temelju dobivenog koeficijenta β_i koji iznosi 0,000009731 zaključuje kako ima pozitivan utjecaj na odzivnu varijablu OLBI. To bi značilo da u slučaju povećanja dohotka po stanovniku za jednu jedinicu, uz sve ostale varijable nepromijenjene, dolazi do povećanja očekivane razine varijable OLBI za 0,000974%. Kako p-vrijednosti pokazuju da nijedna nezavisna varijabla nema statistički značajan utjecaj na očekivanu razinu transparentnosti, zaključuje se da kretanje zavisne varijable nije usko povezano s promjenama u odabranim varijablama.

Nadalje, provodi se test omjera vjerodostojnosti za zasićeni model i model 2. Rezultati su dani na slici 5.3.:

```
Model 1: OLBI ~ st_nez + dohodak + suf_def + rod_grad
Model 2: OLBI ~ stanov + st_nez + dohodak + prihod + suf_def + rod_grad
  Resid. Df Resid. Dev Df Deviance Pr(>Chi)
1       123     20.541
2       121     20.520  2 0.020159     0.99
>
```

Slika 5.3. Test omjera vjerodostojnosti za model 2 i zasićeni model

Izvor: Izrada autora

Kako je nulhipoteza da je model 2 bolji od zasićenog modela, na razini značajnosti od 0,05 se ne odbacuje nulhipoteza u korist hipoteze da je zasićeni model bolji od modela 2. Drugim riječima, model 2 se smatra prihvatljivijim od zasićenog.

Prilikom odabira nezavisnih varijabli za model 3 ponovo se analizira korelacijska matrica prikazana u tablici 5.3. Ponovo se može uočiti koreliranost varijabli dohodak po stanovniku, prihod po stanovniku te broj stanovnika, stoga se iz zasićenog modela izbacuju varijable prihod po stanovniku i dohodak po stanovniku.

Model 3 dan je s:

$$E(OLBI) = Exp(\beta_0 + \beta_1 * stanov + \beta_2 * st_nez + \beta_3 * suf_def + \beta_4 * rod_grad)$$

Dobiveni rezultati nalaze se u tablici 5.9.

	PROCIJENJENI KOEFICIJENT β_i	STANDARDNA GREŠKA	PROMJENA OLBI-JA (U %)	Z VRIJEDNOST	P-VRIJEDNOST
SLOBODNI ČLAN	1,59300000	0,0924800	-	17,229	<2e-16***
STANOV	0,00000073	0,0000053	0,000073	0,327	0,743
ST_NEZ	-0,00827200	0,0074900	0,823788	-1,104	0,269
SUF_DEF	-0,00000154	0,0000399	0,001540	-0,038	0,969
ROD_GRAD	-0,00597300	0,1398000	0,571361	-0.043	0,966

Tablica 5.9. Rezultati Poissonove regresije modela 3

Izvor: Izrada autora

Provedenom regresijom s navedenim modelom dolazi se do zaključka kako pozitivan utjecaj na odzivnu varijablu OLBI ima varijabla broj stanovnika, dok

negativan utjecaj na OLBI imaju stopa nezaposlenosti, suficit/ deficit po stanovniku i rod gradonačelnika.

U ovom modelu nije dobivena ni jedna statistički značaja varijabla. Sve nezavisne varijable, osim stope nezaposlenosti imaju izrazito visoku p-vrijednost. Dakle, ne može se odbaciti nulhipoteza u korist hipoteze da je neka od nezavisnih varijabli statistički značajna za model.

Za varijablu s najmanjom p-vrijednosti, odnosno stopu nezaposlenosti, se na temelju dobivenog koeficijenta β_i koji iznosi -0,008272 zaključuje kako ima negativan utjecaj na odzivnu varijablu OLBI. To bi značilo da u slučaju povećanja stope nezaposlenosti za jednu jedinicu, uz sve ostale varijable nepromijenjene, dolazi do smanjenje očekivane razine varijable OLBI za 0,82%. Koeficijenti uz varijable suficit/deficit po stanovniku kao i rod gradonačelnika također su negativni, ali se zbog visokih p-vrijednosti zaključuje da nijedna nezavisna varijabla nema statistički značajan utjecaj na očekivanu razinu transparentnosti, odnosno da kretanje zavisne varijable nije usko povezano s promjenama u odabranim varijablama.

Provodi se test omjera vjerodostojnosti za zasićeni model i model 3.

Rezultati su dani na slici 5.4.:

```
Model 1: OLBI ~ stanov + st_nez + suf_def + rod_grad
Model 2: OLBI ~ stanov + st_nez + dohodak + prihod + suf_def + rod_grad
  Resid. Df Resid. Dev Df Deviance Pr(>Chi)
1       123     21.437
2       121     20.520  2  0.91626   0.6325
>
```

Slika 5.4. Test omjera vjerodostojnosti za model 3 i zasićeni model

Izvor: Izrada autora

Kako je nulhipoteza da je model 3 bolji od zasićenog modela, na razini značajnosti od 0,05 se ne odbacuje nulhipoteza u korist hipoteze da je zasićeni model bolji od modela 3. Drugim riječima, model 3 bolje opisuje dane podatke od zasićenog.

Pogledom na rezultate sva tri modela dane u tablicama 5.7., 5.8. i 5.9. može se uočiti kako u svakom modelu varijable rod gradonačelnika te suficit/ deficit po

stanovniku imaju najveću p-vrijednost. Nadalje, kreira se model koji neće sadržavati te dvije varijable.

Usporedbom rezidualnih devijanci prva tri modela, vidi se kako je model 2 onaj s najmanjom devijancom, stoga se izbacuju ove dvije varijable iz modela 2.

Novi model, model 4, dan je s:

$$E(OLBI) = Exp(\beta_0 + \beta_1 * st_nez + \beta_2 * dohodak)$$

Analizom procijenjenog modela dobiveni su idući rezultati u tablici 5.10.:

	PROCIJENJENI KOEFICIJENT β_i	STANDARDNA GREŠKA	PROMJENA OLBI-JA (U%)	Z VRIJEDNOST	P-VRIJEDNOST
SLOBODNI ČLAN	1,21300000	0,3650000	-	3,058	0,002**
ST_NEZ	-0,00303300	0,0092290	0,30284	-0,329	0,742
DOHODAK	0,00000971	0,0000097	0,00971	1,003	0,316

Tablica 5.10. Rezultati Poissonove regresije modela 4

Izvor: Izrada autora

Pozitivan utjecaj na odzivnu varijablu OLBI ima dohodak po stanovniku, dok na njega negativno utječe stopa nezaposlenosti.

U ovom modelu ponovo nema ni jedne statistički značaje varijable. Obje nezavisne varijable, imaju izrazito visoku p-vrijednost. Dakle, ne može se odbaciti nulhipoteza u korist hipoteze da je neka od nezavisnih varijabli statistički značajna za model.

Za varijablu s najmanjom p-vrijednosti, odnosno dohodak po stanovniku, na temelju dobivenog koeficijenta koji iznosi 0,00000971 zaključuje se kako ima pozitivan utjecaj na odzivnu varijablu OLBI. To bi značilo da u slučaju povećanja dohotka po stanovniku za jednu jedinicu, uz sve ostale varijable nepromijenjene, dolazi do povećanja očekivane razine varijable OLBI za 0,01%. Kako p-vrijednosti pokazuju da nijedna nezavisna varijabla nema statistički značajan utjecaj na očekivanu razinu transparentnosti, zaključuje se da kretanje zavisne varijable nije usko povezano s promjenama u odabranim varijablama.

Rezultati testa vjerodostojnosti su dani na slici 5.5.:

```
Model 1: OLBI ~ st_nez + dohodak
Model 2: OLBI ~ stanov + st_nez + dohodak + prihod + suf_def + rod_grad
  Resid. Df Resid. Dev Df Deviance Pr(>Chi)
1       125     20.543
2       121     20.520  4 0.022701   0.9999
>
```

Slika 5.5. Test omjera vjerodostojnosti za model 4 i zasićeni model

Izvor: Izrada autora

Kako je nulhipoteza da je model 4 bolji od modela 3 na razini značajnosti od 0,05 se ne odbacuje nulhipoteza u korist alternative. Drugim riječima, model 3 je bolji od modela 4.

Idući model kreirat će se tako da se iz zasićenog modela izbace sve varijable koje imaju p-vrijednost veću od 90%. Pogledom na tablicu 5.6. zaključujemo da su to suficit/ deficit po stanovniku, rod gradonačelnika i broj stanovnika.

Tada je model 5 dan s:

$$E(OLBI) = Exp(\beta_0 + \beta_1 * st_nez + \beta_2 * dohodak + \beta_3 * prihodi)$$

Iz tablice rezultata 5.11. vidljivo je da varijabla dohodak po stanovniku kao i u prethodnom modelu ima najmanju p-vrijednost, dok su ostale p-vrijednosti relativno visoke.

	PROCIJENJENI KOEFICIJENT β_i	STANDARDNA GREŠKA	PROMJENA OLBI-JA (U %)	Z VRIJEDNOST	P-VRIJEDNOST
SLOBODNI ČLAN	1,2220000	0,4028000	-	2,842	0,005
ST_NEZ	-0,0031950	0,0093080	0,3199	-0,329	0,748
DOHODAK	0,0000099	0,0000098	0,0099	0,957	0,339
PRIHOD	-0,0000026	0,0000196	0,0026	-0,329	0,894

Tablica 5.11. Rezultati Poissonove regresije modela 5

Izvor: Izrada autora

Pozitivan utjecaj na odzivnu varijablu OLBI ima dohodak po stanovniku, dok na njega negativno utječe stopa nezaposlenosti te prihodi po stanovniku.

U ovom modelu ponovo ni jednu slučajna varijabla nije statistički značaja. Sve tri varijable, imaju izrazito visoku p-vrijednost. Dakle, ne može se odbaciti nulhipoteza u korist hipoteze da je neka od nezavisnih varijabli statistički značajna za model.

Za varijablu s najmanjom p-vrijednosti, odnosno dohodak po stanovniku, na temelju dobivenog koeficijenta koji iznosi 0,0000099 zaključuje se kako ima pozitivan utjecaj na odzivnu varijablu OLBI. To bi značilo da u slučaju povećanja dohotka po stanovniku za jednu jedinicu, uz sve ostale varijable nepromijenjene, dolazi do povećanja očekivane razine varijable OLBI za 0,01%. Kako p-vrijednosti pokazuju da nijedna nezavisna varijabla nema statistički značajan utjecaj na očekivanu razinu transparentnosti, zaključuje se da kretanje zavisne varijable nije usko povezano s promjenama u odabranim varijablama.

Rezultati testa vjerodostojnosti su dani na slici 5.6.:

```
Model 1: OLBI ~ st_nez + dohodak + prihod
Model 2: OLBI ~ stanov + st_nez + dohodak + prihod + suf_def + rod_grad
  Resid. Df Resid. Dev Df  Deviance Pr(>Chi)
1       124     20.525
2       121     20.520  3 0.0049619   0.9999
> |
```

Slika 5.6. Test omjera vjerodostojnosti za model 5 i zasićeni model

Izvor: Izrada autora

Kako je nulhipoteza da je model 5 bolji od zasićenog modela, na razini značajnosti od 0,05 se ne odbacuje nulhipoteza u korist hipoteze da je zasićeni model bolji od modela 5. Drugim riječima, model 5 se smatra prihvatljivijim od zasićenog.

Izradit će se još i model putem stepwise regresije. Stepwise model izrađuje se pomoću gotove funkcije u R-u. U koracima stepwise regresije iz modela se izbacuju one varijable koje su visoko korelirane s ostalima te imaju zanemariv utjecaj na predviđanje modela. Stepwise model automatski odabire najbolji skup nezavisnih varijabli, a može se koristiti kao provjera prethodno izrađenih modela.

Model dobiven stepwise regresijom prikazan je na slici 5.7.:

```
Start:  AIC=464.62
OLBI ~ stanov + st_nez + dohodak + prihod + suf_def + rod_grad

           Df Deviance    AIC
- rod_grad  1   20.521 462.62
- stanov    1   20.522 462.62
- suf_def   1   20.523 462.62
- prihod    1   20.538 462.63
- st_nez    1   20.629 462.72
- dohodak   1   21.436 463.53
<none>          20.520 464.62

Step:  AIC=462.62
OLBI ~ stanov + st_nez + dohodak + prihod + suf_def

          Df Deviance    AIC
- stanov   1   20.523 460.62
- suf_def  1   20.523 460.62
- prihod   1   20.539 460.63
- st_nez   1   20.630 460.73
- dohodak  1   21.438 461.53
<none>         20.521 462.62

Step:  AIC=460.62
OLBI ~ st_nez + dohodak + prihod + suf_def

          Df Deviance    AIC
- suf_def  1   20.525 458.62
- prihod   1   20.541 458.64
- st_nez   1   20.641 458.74
- dohodak  1   21.543 459.64
<none>         20.523 460.62

Step:  AIC=458.62
OLBI ~ st_nez + dohodak + prihod

          Df Deviance    AIC
- prihod   1   20.543 456.64
- st_nez   1   20.643 456.74
- dohodak  1   21.546 457.64
<none>         20.525 458.62

Step:  AIC=456.64
OLBI ~ st_nez + dohodak

          Df Deviance    AIC
- st_nez   1   20.651 454.75
- dohodak  1   21.546 455.64
<none>         20.543 456.64

Step:  AIC=454.75
OLBI ~ dohodak

          Df Deviance    AIC
<none>         20.651 454.75
- dohodak  1   22.847 454.94
>
```

Slika 5.7. Stepwise model u R-u

Izvor: Izrada autora

Vidimo kako odabrani model uz slobodan član ovisi o samo jednoj varijabli. Prema stepwise regresiji, najbolji je model dobiven jednostrukom Poissonovom regresijom u kojem zavisna varijabla OLBI ovisi samo o dohotku po stanovniku.

Izborom različitih nezavisnih varijabli te izbacivanjem pojedinih varijabli iz modela radi velike koreliranosti s ostalima, izrađeno je nekoliko prediktorskih modela. Uspoređivanjem modela međusobno došlo se do zaključka kako modeli s manjim brojem varijabli (nakon što se iz zasićenog modela izbace korelirane varijable) bolje leže uz dane podatke od punog modela. Stepwise regresijom potvrđeno je kako je najbolji model dobiven jednostrukom Poissonovom regresijom koji sadrži samo varijablu dohodak po stanovniku.

5.5. Analiza i interpretacija rezultata

Provedeni su testovi prilagodbe modela (Pearsonov i test devijance) te se zbog visokih p vrijednosti zaključuje kako svaki od modela dobro opisuje podatke. Napravit će se još i analizu modela na temelju njihovih devijanci i AIC kriterija.
Null devijanca pokazuje koliko su podaci dobro opisani slobodnim članom, tj. osnovnim modelom bez nezavisnih varijabli, dok rezidualna devijanca pokazuje koliko dobro prediktorski model opisuje dane podatke.
Rezidualna varijanca u svakom od modela je manja od null devijance što se može vidjeti u tablici 5.12., pa je stoga moguće zaključiti kako je prikladniji model koji sadrži sve uključene nezavisne parametre.

VARIJABLA	NULL DEVIJANCA	REZIDUALNA DEVIJANCA	AIC
ZASIĆENI MODEL	22,847 (127)	20,520 (121)	464,62
MODEL 1	22,847 (127)	21,539 (123)	461,63
MODEL 2	22,847 (127)	20,541 (123)	460,64
MODEL 3	22,847 (127)	21,437 (123)	461,53
MODEL 4	22,847 (127)	20,525 (124)	456,64
MODEL 5	22,847 (127)	20,543 (125)	458,62
STEPWISE MODEL	22,847 (127)	20,651 (126)	454,75
JEDNOSTRUKI (DOHODAK)	22,847 (127)	20,651 (126)	454,75

Tablica 5.12. Usporedba procijenjenih modela

Izvor: Izrada autora

Prema AIC kriteriju najprikladniji je onaj model koji postiže najnižu AIC vrijednost. Iz tablice 5.12. vidi se da bi to bio model dobiven jednostrukom Poissonovom regresijom (tablica 5.4.) koji sadrži samo dohodak po stanovniku što se potvrđuje i Stepwise funkcijom.

Međutim, to ne mora značiti kako je baš taj model najbolji. Rezultate treba uzeti s dozom opreza jer model koji ima manji broj varijabli ima i manju AIC vrijednost. Također, veća koreliranost među nezavisnim varijablama i modeli s različitim brojem nezavisnim varijabli dovode do različitih AIC vrijednosti.

Ranije je spomenuto svojstvo ekvidisperzije koje je glavni uvjet Poissonove regresije. To znači da bi uvjetno očekivanje i varijanca trebali biti jednaki. Provjerit će se svojstvo ekvidisperzije testom ekvidisperzije za najbolji model, a to je model jednostruke Poissonove regresije koji sadrži varijablu dohodak po stanovniku. Svojstvo se provjerava naredbom dispersiontest u R-u. Zbog vrlo niske p-vrijednosti (2,2e-16) odbacuje se nulhipoteza o zadovoljenom svojstvu ekvidisperzije u korist alternative kako je to svojstvo narušeno. Odnosno, uvjetno očekivanje je manje od uvjetne varijance, stoga je potrebno napraviti i kvazi Poissonov model koji će bolje opisivati dane podatke.

Ponovit će se jednadžba modela s jednom nezavisnom varijablom:

$$E(OLBI) = Exp(\beta_0 + \beta_1 * dohodak)$$

U tablici 5.13. nalaze se rezultati Poissonove regresije za kvazi Poissonov model.

	PROCIJENJENI KOEFICIJENT β_i	STANDARDNA GREŠKA	PROMJENA OLBI-JA (U %)	Z VRIJEDNOST	P-VRIJEDNOST
SLOBODNI ČLAN	1,1160000	0,1010000	-	11,048	<2e-16***
DOHODAK	0,0000116	0,0000029	0,0017	3,939	0,000135***

Tablica 5.13. Rezultati kvazi Poissonovog modela

Izvor: Izrada autora

Usporede li se dobivene vrijednosti s onima iz tablice 5.4. vidi se kako se standardna greška smanjila. Ujedno se smanjila i p-vrijednost pa se sada nalazi ispod razine značajnosti te se može zaključiti kako je varijabla dohodak po stanovniku na odabranoj razini značajnosti od 5% statistički značajna i bitno utječe na promjenu OLBI-ja.

Za povećanje dohotka po stanovniku za jednu kunu, uz sve ostale varijable nepromijenjene, očekivana razina OLBI-ja poveća se za 0,0017%.

Ovime je potvrđena hipoteza postavljena u poglavlju 2.5. Veći dohodak po stanovniku implicira bolji životni standard, pa ljudi imaju i bolji pristup internetu. Ljudi s većim dohotkom obično imaju i veći stupanj obrazovanja. Radi toga, uz bolje uvjete i lakši pristup proračunskim dokumentima dovodi i do veće potražnje, a time pozitivno utječe na proračunsku transparentnost [33].

Zaključno, analiza odabranih odrednica proračunske transparentosti gradova u RH potvrdila je djelomično postavljene hipoteze. Ovisno od modela do modela rod gradonačelnika kao i suficit/deficit po stanovniku mogu imati i negativan i pozitivan utjecaj na razinu OLBI-ja. No zbog visoke razine p-vrijednosti kao i velike korelacije među varijablama nije se moglo na razumnoj razini značajnosti reći kako te varijable imaju statistički značajan utjecaj na razinu OLBI-ja. Ipak, ostale su varijable u svakom od modela potvrdile postavljene hipoteze. Tako se pokazalo da broj stanovnika, dohodak i prihodi po stanovniku uvijek pozitivno utječu na OLBI, dok stopa nezaposlenosti ima negativan utjecaj na OLBI.

Jednostrukom i višestrukom analizom Poissonovih modela došlo se do onog najboljeg koji sadrži samo jednu nezavisnu varijablu, dohodak po stanovniku, a zatim se to i potvrdilo pomoću gotove naredbe u R-u za stepwise proceduru, krenuvši od zasićenog modela redom odbacujući nepotrebne varijable.

U svakom je modelu svojstvo preraspršenosti bilo narušeno pa bi stoga za točniju analizu bilo potrebno izraditi kvazi Poissonove modele. Napravljen je kvazi Poissonov model za najbolji odabrani model te je dana analiza i interpretacija rezultata.

6. ZAKLJUČAK

Unatoč velikom broju različitih definicija proračunske transparentnosti, u osnovi svih definicija je ideja da vlada mora objavljivati pravovremene, točne, razumljive i pouzdane informacije. No, nije dovoljno samo da vlade objavljuju informacije kako bi se proračunska transparentnost povećala, već je važno da građanstvo bude aktivni sudionik tog procesa. Istraživanja su pokazala kako je razina indeksa OLBI u RH u porastu, ali je proračun hrvatskih jedinica lokalne samouprave nedovoljno transparentan jer hrvatski građani nedovoljno sudjeluju u proračunskom procesu.

Zbog nepostojanja jedinstvene definicije proračunske transparentnosti ne postoji niti jedinstveni način njezinog mjerenja. U budućnosti ostaje izazov napraviti standardizirano mjerenje razine proračunske transparentnosti među državama u čitavom svijetu. Veliki doprinos istraživanju proračunske transparentnosti u RH daje IJF. Već godinama stručnjaci sa IJF-a mjere razinu proračunske transparentnosti hrvatskih općina, gradova i županija indeksom OLBI.

Ovaj je rad posvećen istraživanju proračunske transparentnosti na razini jedinica lokalne samouprave u RH, točnije na razini gradova. Na uzorku od 128 gradova testirano je nekoliko odrednica proračunske transparentnosti i postavljene su hipoteze o njihovom pozitivnom ili negativnom tjecaju na razinu OLBI-ja. Analiziran je utjecaj šest nezavisnih varijabli; dohodak po stanovniku, broj stanovnika, stopa nezaposlenosti, suficit/deficit po stanovniku, prihodi po stanovniku i rod gradonačelnika.

U nastavku rada navedene varijable su korištene za konstrukciju modela koji bi najbolje opisivao OLBI. Kako je OLBI (zavisna varijabla) obilježen diskretnim nenegativnim vrijednostima, korištena je Poissonova regresija s ciljem utvrđivanja nezavisnih varijabli koje imaju pozitivan ili negativan utjecaj na razinu transparentnosti i kolika je točna razina utjecaja određene nezavisne varijable na OLBI. Nakon provedene regresijske analize zaključeno je kako samo varijabla dohodak po stanovniku statistički značajno i to pozitivno utječe na zavisnu

varijablu OLBI, tj. na razinu proračunske transparentnosti svih gradova u RH. Ostale varijable se nisu pokazale statistički značajnima.

Važno je napomenuti da postoje manjkavosti u provedenom istraživanju i njegovim rezultatima. Pokazalo se kako je većina varijabli pozitivno ili negativno korelirana s visokim koeficijentom korelacije; stopa nezaposlenosti je negativno korelirana s dohotkom po stanovniku, dok je dohodak po stanovniku pozitivno koreliran s brojem stanovnika i prihodima po stanovniku. Postoje i brojne druge varijable čiji se utjecaj na razinu proračunske transparentnosti u ovom radu nije proučavao. Svakako bi bilo zanimljivo vidjeti kako ostale ekonomske, političke i socijalne varijable utječu na OLBI.

Druga je mana vrijeme prikupljanja podataka jer je većina korištenih podataka zastarjela. Nadalje, testovima disperzije se pokazalo kako je narušeno svojstvo ekvidisperzije u svakom modelu, pa bi bilo potrebno napraviti kvazi Poissonove modele koji bi bolje opisivali dane podatke.

Buduća istraživanja razine proračunske transparentnosti mogla bi uključiti novije podatke nakon što oni budu dostupni, a neki su već i postali dostupni prilikom izrade ovog rada. Također, u cilju usavršavanja mogao bi se poboljšati i indeks OLBI tako da umjesto uz mjerenje objavljenih dokumenata na mrežnim stranicama, ocjenjuje i kvalitetu sadržaja tih dokumenata i njihovu dostupnost na internetu. Tu se pojavljuje i mogućnost da Vlada izda zakonsku obvezu kojom bi lokalne jedinice morale objaviti sve proračunske dokumente te da se kazni svaka jedinica koja to ne učini u točno određenim vremenskim intervalima i u zadanim formatima.

Uz vladine sankcije i veći pritisak javnosti, pa i bolju edukaciju građana o političkim i ekonomskim pojmovima i zbivanjima, razina proračunske transparentnosti u RH mogla bi se još više povećati.

LITERATURA

[1] J. M. Aguirre, Jose. (2015). *Overview of Transparency and Openness Literature.,* dostupno na https://www.researchgate.net/publication/303460446_Overview_of_Transparency_and_Openness_Literature/link/5744419508ae9f741b3b384c/download (kolovoz 2020.)

[2] J. E. Alt, D. Dreyer Lassen, Sh. Rose, *The Causes of Fiscal Transparency: Evidence from the American States*, dostupno na https://www.imf.org/external/np/res/seminars/2005/arc/pdf/alt.pdf (lipanj 2020.)

[3] J.F.F.E. Araujo, *Does Gender Equality Affect Municipal Transparency: The Case of Spain,* dostupno na https://www.tandfonline.com/doi/full/10.1080/15309576.2017.1362350?scroll=top&needAccess=true (kolovoz 2020.)

[4] B. Basrak, *Generalizirani linearni modeli*, dostupno na https://web.math.pmf.unizg.hr/~bbasrak/pdf_files/FinPrak/FPchap7.pdf (lipanj 2020.)

[5] M. Bauhr, M. Grimes, *Transparency to curb corruption? Concepts, measures and empirical merit. Crime Law Soc Change 68, 431–458 (2017).* dostupno na https://doi.org/10.1007/s10611-017-9695-1 preuzeto 10.08.2020.

[6] T. Berglund, *Corporate Governance and Optimal Transparency. The Oxford Handbook of Economic and Institutional Transparency.* (2014);:358–70.

[7] J.C. Bertot, P.T. Jaeger, J.M. Grimes, *Using ICTs to create a culture of transparency: E-government and social media as openness and anti-corruption tools for societies. Government Information Quarterly.* (2010);27(3):264–71.

[8] J. Caamaño-Alegre, S. Lago-Peñas, F. Reyes-Santias i A. Santiago-Boubeta, *Budget transparency in local governments: An Empirical Analysis (2013.), dostupno na*

https://www.tandfonline.com/doi/abs/10.1080/03003930.2012.693075 (kolovoz 2020.)

[9] A. Cuervo-Cazurra, Transparency and Corruption. The Oxford Handbook of Economic and Institutional Transparency. (2014), 322–38.

[10] DZS, *Baze podataka*, https://www.dzs.hr/PXWeb/Selection.aspx?px_path=Stanovni%c5%a1tvo__Procjene%20stanovni%c5%a1tva&px_tableid=SP31_2.px&px_language=hr&px_db=Stanovni%c5%a1tvo&rxid=3ce8d439-b310-4eb6-95d5-81a9720e76bd#VariableSelection (srpanj 2020.)

[11] Grad Rijeka, *Što je proračun? Kako se planira, izvršava i kontrolira?,* dostupno na https://www.rijeka.hr/gradska-uprava/proracun/sto-proracun-se-planira-izvrsava-kontrolira/ (rujan 2020.)

[12] Grad Zagreb, *Vodič kroz proračun Grada Zgreba*, dostupno na https://www.zagreb.hr/UserDocsImages/arhiva/financije/ZG_vodic_kroz_proracun_web%20241114.pdf (kolovoz 2020.))

[13] M-D. Guillamón, F. Bastida, B. Benito, *The Determinants of Local Government's Financial Transparency,* https://www.tandfonline.com/doi/full/10.1080/03003930.2011.588704 (lipanj 2020.)

[14] D. Heald, *Varieties of Transparency. Transparency: The Key to Better Governance?* 2006

[15] IJF, *Karta gradova i općina*, dostupno na http://www.ijf.hr/transparentnost/gradovi/ (srpanj 2020)

[16] IJF, *Proračunski vodič za građane 2013*, dostupno na http://www.ijf.hr/proracunski/I-proracun.pdf (kolovoz 2020.)

[17] IJF, *Proračunska transparentnost županija, gradova i općina studeni 2019.-travanj 2020.*, http://www.ijf.hr/upload/files/file/newsletter/119.pdf (lipanj 2020.)

[18] IMF, How Does the IMF Encourage Greater Fiscal Transparency, dostupno na https://www.imf.org/en/About/Factsheets/Sheets/2016/07/27/15/46/Encouraging-Greater-Fiscal-Transparency (kolovoz 2020.)

[19] International Monetary Fund, *Fiscal transparency*, dostupno na http://www.imf.org/external/np/fad/trans (rujan 2020.)

[20] C. Lindstedt, D. Naurin, *Transparency is not Enough: Making Transparency Effective in Reducing Corruption. International Political Science Review. 2010;31(3):301-322. doi:10.1177/0192512110377602,* dostupno na https://doi.org/10.1177/0192512110377602 (lipanj 2020.)

[21] L. Ma i J. Wu, *What drives fiscal transparency? Evidence from provincial governments in China, (2011).*

[22] Ministarstvo financija, *Financijski izvještaji*, dostupno na https://mfin.gov.hr/istaknute-teme/lokalna-samouprava/financijski-izvjestaji-jlp-r-s/pr-ras-i-ras-funkc-za-razdoblje-2014-2018/208 (srpanj 2020.)

[23] Ministarstvo regionalnog razvoja i fondova Europske unije, *Indeks razvijenosti*, dostupno na https://razvoj.gov.hr/UserDocsImages//O%20ministarstvu/Regionalni%20razvoj/indeks%20razvijenosti//Vrijednosti%20indeksa%20razvijenosti%20i%20pokazatelja%20za%20izra%C4%8Dun%20indeksa%20razvijenosti_jedinice%20lokalne%20samouprave.pdf (srpanj 2020.)

[24] Ministarstvo uprave, *Lokalna i područna (regionalna) samouprava*, dostupno na https://uprava.gov.hr/o-ministarstvu/ustrojstvo/uprava-za-politicki-sustav-drzavnu-upravu-te-lokalnu-i-podrucnu-regionalnu-samoupravu/lokalna-i-podrucna-regionalna-samouprava/842 (kolovoz 2020.)

[25] Narodne novine, *Zakon o lokalnoj i područnoj (regionalnoj) samoupravi,* https://narodne-novine.nn.hr/clanci/sluzbeni/2001_04_33_569.html (rujan 2020.)

[26] NCSS Statistical software, *Chapter 325 Poisson Regression,* dostupno na https://www.ncss.com/wp-content/themes/ncss/pdf/Procedures/NCSS/Poisson_Regression.pdf (kolovoz 2020.)

[27] OECD, *Glossary of the statistical terms*, dostupno na https://stats.oecd.org/glossary/detail.asp?ID=7294 (lipanj 2020)

[28] OECD, *OECD Best Practices for Budget Transparency*, dostupno na https://www.oecd.org/governance/budgeting/Best%20Practices%20Budget%20Transparency%20-%20complete%20with%20cover%20page.pdf (kolovoz 2020)

[29] K. Ott, M. Bronić, M. Petrušić, B. Stanić i S. Prijaković, *Proračunska transparentnost županija, gradova i općina : studeni 2019. – travanj 2020.*, dostupno na http://www.ijf.hr/upload/files/file/newsletter/119.pdf (lipanj 2020.)

[30] C. C. Pérez, M. P. R. Bolívar, A. M. López Hernández, *E-Government process and incentives for online public financial information*, dostupno na https://www.sciencedirect.com/science/article/abs/pii/S0740624X05000183 (kolovoz 2020.)

[31] PMF, *Metoda maksimalne vjerodostojnosti*, dostupno na https://web.math.pmf.unizg.hr/nastava/stat/files/chap4_novo.pdf (kolovoz 2020.)

[32] C. Serrano-Cinca, M. Rueda-Tomás i P. Portillo-Tarragona, *Factors Influencing E-Disclosure in Local Public Administrations. Environment and Planning C: Government and Policy,* dostupno na https://journals.sagepub.com/doi/10.1068/c07116r (kolovoz 2020.)

[33] A.K. Styles i M. Tennyson*, The accessibility of financial reporting of US municipalities on the Internet, Journal of Public Budgeting, Accounting & Financial Management 19* (2007), br. 1, 56.

[34] A.F. Tavares, N.F. da Cruz , *Explaining the transparency of local government websites through a political market framework* http://eprints.lse.ac.uk/84127/1/da%20Cruz_Explaining%20transparency_2017.pdf (kolovoz 2020.)

[35] M. Templier & G. Pare (2018). *Transparency in literature reviews: an assessment of reporting practices across review types and genres in top IS journals. European Journal of Information Systems. 27. 503-550. 10.1080/0960085X.2017.1398880.,* dostupno na https://www.tandfonline.com/doi/abs/10.1080/0960085X.2017.1398880 (kolovoz 2020.)

SAŽETAK

Interes za proučavanjem odrednica koje utječu na proračunsku transparentnost je u porastu kako u svijetu tako i u RH. Transparentnost proračuna omogućuje građanima da vrednuju rad vlasti na lokalnoj i državnoj razini, da sami doprinose proračunskom procesu i da dobiju bolji uvid u financijsko stanje.

Cilj ovog rada bio je odrediti i analizirati odrednice proračunske transparentnosti 128 hrvatskih gradova. Promatrani indeks proračunske transparentnosti OLBI mjeri se brojem objavljenih ključnih proračunskih dokumenata na internetskim stranicama lokalnih jedinica i poprima vrijednosti u rasponu od 0 do 5.

Poissonovom regresijom ispituje se utjecaj šest odabranih varijabli: rod gradonačelnika, dohodak po stanovniku, suficit/deficit po stanovniku, prihodi po stanovniku, broj stanovnika i stope nezaposlenosti na razinu proračunske transparentnosti hrvatskih gradova.

Rezultati ukazuju na to kako samo dohodak po stanovniku statistički značajno utječe na razinu proračunske transparentnosti u hrvatskim gradovima čime je potvrđena jedna od postavljenih hipoteza rada.

Proračunska je transparentnost u RH u porastu, no ostaje izazov i poticaj za boljom edukacijom i većom angažiranošću građana u cijelokupnom proračunskom procesu.

SUMMARY

Interest in studying the determinants that affect budget transparency is growing both in the world and in the Republic of Croatia. Budget transparency enables citizens to value the work of government at the local and state levels, to contribute to the budget process themselves and to gain a better insight into the financial situation.

The aim of this paper was to determine and analyze the determinants of budget transparency of 128 Croatian cities. Observed budget transparency index OLBI is measured by the number of published key budget documents on the websites of local units and it takes values in the range from 0 to 5.

Poisson's regression examines the impact of six selected variables: mayor's gender, income per capita, surplus / deficit per capita, income, estimated population and unemployment rates on the level of budget transparency of Croatian cities.

The results indicate that only income per capita has statistically significant affect the level of budget transparency in Croatian cities, which confirms one of the set hypotheses.

Budget transparency in the Republic of Croatia is increasing, but still there remains the challenge and incentive for better education and greater involvement of citizens in the entire budget process.

ŽIVOTOPIS

Iva Artuković rođena je 1. travnja 1994. godine u Zagrebu gdje je i odrastala. Upisuje se u Osnovnu školu „Luka“ u Sesvetama, a nakon osnovne kreće u Srednju školu Sesvete. Nakon završetka srednjoškolskog obrazovanja u Srednjoj školi Sesvete, a današnjoj Općoj gimnaziji Sesvete, 2012. godine upisuje Preddiplomski studij Matematike na Prirodoslovno- matematičkom fakultetu Sveučilišta u Zagrebu, Matematički odsjek. Diplomski studij nastavlja na istom fakultetu 2016. godine. Od 2019. godine zapošljava se u H5. d.o.o. na mjesto suradnika u projektiranju.