Proračunska transparentnost i proračunski ishodi lokalnih jedinica: usporedba hrvatskih regija

Kesteli, Valerija

Master's thesis / Diplomski rad

2022

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:217:051630

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2025-03-24**

Repository / Repozitorij:

Repository of the Faculty of Science - University of Zagreb

SVEUČILIŠTE U ZAGREBU

PRIRODSLOVNO-MATEMATIČKI FAKULTET

MATEMATIČKI ODSJEK

Valerija Kesteli

PRORAČUNSKA TRANSPARENTNOST I PRORAČUNSKI ISHODI LOKALNIH JEDINICA: USPOREDBA HRVATSKIH REGIJA

Diplomski rad

Zagreb, 2022.

SVEUČILIŠTE U ZAGREBU

PRIRODSLOVNO-MATEMATIČKI FAKULTET

MATEMATIČKI ODSJEK

Valerija Kesteli

PRORAČUNSKA TRANSPARENTNOST I PRORAČUNSKI ISHODI LOKALNIH JEDINICA: USPOREDBA HRVATSKIH REGIJA

Diplomski rad

Voditeljica rada:

prof. dr. sc. Katarina Ott

Zagreb, 2022.

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 2
2. PREGLED LITERATURE 4
2.1. VARIJABLE I HIPOTEZE 6
2.1.1. Proračunska transparentnost 6
2.1.2. Proračunski ishodi 7
2.1.3. Direktni dug po stanovniku 9
2.1.4. Prihodi od poreza po stanovniku 9
3. PODACI I METODOLOGIJA 11
3.1. PODACI 11
3.2. METODOLOGIJA - GENERALIZIRANI LINEARNI MODEL (GLM) 12
3.2.1. Eksponencijalne familije 13
3.2.2. Generalizirani linearni modeli (GLM) 15
3.2.1. Poissonova regresija 18
3.2.2. Procjena parametara 19
3.2.3. Odabir modela 21
4. EMPIRIJSKA ANALIZA 26
4.1. DESKRIPTIVNA STATISTIKA 26
4.1.1. Deskriptivna statistika regija 2014.-2020. 26
4.1.2. Deskriptivna statistika regija 2017. i 2019. 28
4.2. POISSONOVA REGRESIJA 35
4.2.1. Sjeverna Hrvatska 35
4.2.2. Središnja Hrvatska 39
4.2.3. Istočna Hrvatska 42
4.2.4. Jadranska Hrvatska 46
4.2.5. Dalmacija 50
4.2.6. Usporedba rezultata iz 2017. i 2019. 53
5. ZAKLJUČAK 55
LITERATURA 57
DODATAK 60
SAŽETAK 61
SUMMARY 62
ŽIVOTOPIS 63

1. UVOD

Regionalne razlike prepoznate su kao jedna od prepreka vođenju zdrave ekonomske politike. Znanstvenici političke ekonomije i ekonomije javnog sektora ističu ulogu javnih financija, odnosno proračunskih ishoda i cjelokupnog zajedničkog djelovanja u tom procesu.

Cilj rada je proučiti razlike među regijama Republike Hrvatske (RH) koje su definirane područnim uredima Porezne uprave (Sjeverna Hrvatska, Središnja Hrvatska, Istočna Hrvatska, Jadranska Hrvatska, Dalmacija i Grad Zagreb) te razlike između lokalnih jedinica unutar svake regije u okviru proračunske transparentnosti i proračunskih ishoda.

Nadalje, ispituje se statistička značajnost utjecaja ekonomskih varijabli na proračunsku transparentnost lokalnih jedinica u pojedinim hrvatskim regijama.

Kao mjera proračunskih ishoda koristi se udio poslovnih (operativnih) suficita/deficita lokalnih jedinica u njihovim poslovnim (operativnim) prihodima (u radu – $stor$), dok je proračunska transparentnost izražena indeksom otvorenosti lokalnih proračuna (u radu – OLBI), koji se godišnje mjeri za sve hrvatske županije, gradove i općine.

Empirijska analiza rada može se podijeliti na dva dijela.

Prvi dio proučava razlike među regijama pomoću deskriptivne statistike na uzdužnim podacima (*panel data*) o lokalnim jedinicama za razdoblje od 2014. do 2020. i na vremenski presječenim podacima (*cross-sectional data*) o lokalnim jedinicama za 2019. te za 2017. Godina 2019. odabrana je kao posljednja godina prije početka širenja pandemije koronavirusa i time uzrokovane gospodarske krize. Kako se s godinama povećava indeks otvorenosti lokalnih proračuna, razlike među lokalnim jedinicama su sve manje. Iz tog razloga je odabrana i 2017. za analizu kako bi se usporedili rezultati regresije dobiveni u 2017. i 2019.

Drugi dio utvrđuje koje ekonomske varijable statistički značajno utječu na proračunsku transparentnost lokalnih jedinica u pojedinim hrvatskim regijama prema podacima iz 2019. Prema teoriji generaliziranih linearnih modela, proračunska transparentnost lokalne jedinice promatra se kao zavisna varijabla ili varijabla odziva, dok su za nezavisne varijable, tzv. kovarijate, odabrane slijedeće ekonomske varijable: proračunski ishodi, prihodi od poreza po stanovniku i direktni dug po stanovniku lokalne jedinice. Nezavisne varijable odabrane su pregledom literature stranih i domaćih autora. Provedena je Poissonova regresija koja se pokazala najboljom kada varijable poprimaju cjelobrojne vrijednosti, a upravo je takva varijabla proračunske transparentnosti koja poprima cjelobrojne vrijednosti od 0 do 5.

Dobivena su dva značajna Poissonova modela koristeći podatke iz 2019. Za lokalne jedinice regije Istočna Hrvatska dobiveno je kako na razinu proračunske transparentnosti pozitivno statistički značajno utječe varijabla prihod od poreza po stanovniku. Za lokalne jedinice regije Dalmacija dobiveno je kako na razinu proračunske transparentnosti pozitivno statistički značajno utječe varijabla direktni dug po stanovniku.

Komparativna panel analiza šest hrvatskih regija ukazuje na to kako najnižu razinu proračunske transparentnosti imaju iste regije koje imaju najlošije proračunske ishode prema mjeri $stor$, a to su: Sjeverna Hrvatska, Dalmacije i Istočna Hrvatska. Najbolje proračunske ishode te najvišu razinu proračunske transparentnosti ima Grad Zagreb.

Očekuje se da će rad pridonijeti literaturi povezujući važnost transparentnosti – preduvjeta za sudjelovanje građana u proračunskim procesima – za proračunske rezultate u Republici Hrvatskoj.

Rad započinje pregledom literature, definiranjem varijabli i hipoteza. Zatim slijedi poglavlje o izvoru podataka i metodologiji korištenoj u ključnom poglavlju, empirijskoj analizi, koja se grana na dva dijela: deskriptivnu statistiku i Poissonovu regresiju. Rad završava kritičkim osvrtom i zaključkom.

2. PREGLED LITERATURE

Preraspodjela RH na regije već je desetljećima tema brojnih rasprava, s ciljem poboljšanja postojećeg modela decentralizacije (administrativne, upravne i fiskalne) te boljeg praćenja regionalnog razvitka.

Glavna pitanja koja se obično naglašavaju u tekućoj raspravi o hrvatskom regionalnom razvoju su veliki broj jedinica lokalne samouprave (JLS), preklapanje njihovih funkcija i odgovornosti, kao i ograničeni fiskalni kapaciteti (tj. ograničene sposobnosti lokalnih jedinica da vlastitim proračunskim sredstvima financiraju proračunske rashode). (vidi [3] i [19])

S obzirom na trenutni nedostatak fiskalnog uspjeha hrvatskih JLS-a, u literaturi se zaključuje da je to izravna posljedica neadekvatnih procesa decentralizacije provedenih 1990-ih, što je rezultiralo lokalnim proračunima koji imaju prije svega društvenu i političku, a ne gospodarsku funkciju. To je ugrozilo i stabilizacijsku funkciju javnih financija. (vidi [14], [17] i [18])

Regionalne razlike prepoznate su kao jedna od prepreka vođenju zdrave ekonomske politike.

Znanstvenici političke ekonomije i ekonomije javnog sektora ističu ulogu javnih financija, odnosno proračunskih ishoda i cjelokupnog kolektivnog djelovanja u tom procesu. (vidi [23])

Europska unija (EU), čijim članom je RH postala 2013., primjenjuje zajedničko razvrstavanje prostornih jedinica za statistiku, nazvano „NUTS“ (***N****omenclature des* ***u****nités* ***t****erritoriales* ***s****tatistiques*), radi lakšeg prikupljanja, obrade i objavljivanja usklađenih regionalnih statističkih podataka u Europskoj uniji.

Općenito, regije se formiraju zbog učinkovitog vođenja regionalne razvojne politike. Glavni prioriteti regionalne politike EU su prepoznavanje nerazvijenih područja EU i potpora njihovom gospodarskom razvoju. (vidi [2])

Osnovni cilj regionalne politike EU jest:

1) smanjenje nejednakosti između bogatijih i siromašnijih regija, odnosno rast životnog standarda i kvalitete života
2) gospodarska i društvena kohezija te solidarnost između država članica.

U trenutku pisanja ovog rada, najnovija Nacionalna klasifikacija statističkih regija (uvedena 2020.), podijelila je državu na četiri statističke regije: Panonska Hrvatska, Jadranska Hrvatska, Grad Zagreb i Sjeverna Hrvatska, čime je podjela na dvije NUTS 2 statističke regije iz 2012. (Kontinentalna i Jadranska Hrvatska) službeno prestala vrijediti. Zbog odluke o promjeni regionalnog ustroja ubuduće bi trebalo postati puno lakše pratiti proračun te neto fiskalne

pozicije (razlika ukupnih prihoda i rashoda poslovanja) prema regionalnoj dimenziji, s ciljem boljeg regionalnog razvitka (vidi [4]) kao što je raspravljano još 2015. (vidi [13]).

Iduća preraspodjela NUTS regija moguća je tri godine nakon zadnje promjene.

Područnim uredima Porezne uprave definirana je podjela RH na idućih šest regija: Grad Zagreb, Središnja Hrvatska, Sjeverna Hrvatska, Istočna Hrvatska (Slavonija i Baranja), Jadranska Hrvatska (Istra, Hrvatsko primorje, Gorski kotar i Lika) i Dalmacija.

U ovom radu utvrđuje se neto fiskalni položaj svake regije putem mjere proračunskih ishoda (oznaka: STOR), koja je izračunata kao udio razlike poslovnih prihoda i poslovnih rashoda poslovanja u ukupnim poslovnim prihodima poslovanja.

Prihodi poslovanja (tzv. operativni prihodi) lokalnih jedinica prosječno su, u zadnjih pet godina, činili 97% ukupnih prihoda, dok se preostalih 3% prikupilo od prihoda od prodaje nefinancijske imovine.

Prihodi poslovanja nastaju redovnim poslovanjem lokalne jedinice, dok prihodi od prodaje nefinancijske imovine potječu od prodaje kapitalne imovine lokalne jedinice što se može okarakterizirati kao izvanredna poslovna aktivnost. Zato se rad koncentrira na podatke o poslovnim (operativnim) prihodima.

Za jedinice koje ostvaruju najbolje rezultate prema mjeri proračunskih ishoda (STOR, tzv. financijske uspješnosti) to je svojevrsna potvrda uspješnosti koja im može pomoći u lobiranju za povećanje sredstava iz proračuna opće države ili dobar argument za daljnju decentralizaciju.

Važnost teritorijalnog ustroja potvrđena je u brojnim radovima. Prema Rašić Bakarić et. al (vidi [25]), statističkom analizom sugerirano je da je pripadnost gradova širim regijama najvažnija determinanta njihove ekonomske uspješnosti.

Naime, za svaku državu članicu Europske unije vrlo je bitno imati učinkovitu podjelu na NUTS regije pošto slabije razvijene regije zemalja članica imaju pravo na financiranje pojedinih projekata iz proračuna EU, iz Kohezijskog i strukturnih fondova (vidi [2]).

Dodatni argument uspješnosti regije, koji je moguće koristiti u svrhu povećanja financijskih sredstava, može biti i visoki indeks proračunske transparentnosti (OLBI). U brojnim istraživanjima dokazano je kako je proračunska transparentnost bitna za proračunski učinak.

2.1. VARIJABLE I HIPOTEZE

Pregledom empirijskih istraživanja, provedenih između 2000. i 2017., o varijablama koje određuju proračunsku transparentnost, došlo se do najčešće korištenih nezavisnih varijabli (tzv. kovarijata) te se one mogu se svrstati u tri kategorije (vidi [26]):

1. Ekonomske – dug, dohodak, proračunski saldo etc.
2. Političke – politička konkurencija, politička ideologija, izlaznost na izbore etc.
3. Građani i mediji – broj stanovnika (gustoća naseljenosti), karakteristike građana, dohodak građana, pristup internetu etc.

U ovom radu razmatra se utjecaj ekonomskih varijabli na proračunsku transparentnost.

Odabrane su tri ekonomske varijable: proračunski ishodi proračunski saldo, prihodi od poreza po stanovniku i direktni dug po stanovniku.

Hipoteze su navedene u opisu nezavisnih varijabli.

2.1.1. Proračunska transparentnost

Pod pojmom proračunska transparentnost podrazumijeva se uvid u potpune, točne, pravovremene i razumljive proračunske informacije. Na temelju njih građani se mogu angažirati i pokušati utjecati na efikasnost prikupljanja i trošenja proračunskih sredstava, odgovornost vlasti lokalnih jedinica, kao i na smanjenje mogućih koruptivnih radnji. (vidi [21])

Sve je više istraživanja o tome što određuje proračunsku transparentnost, iz kojih razloga neke lokalne jedinice u RH, tj. gradovi i općine, zaostaju u tom smjeru. Nastoji se potaknuti sve lokalne jedinice da godišnje objave 5 ključnih proračunskih dokumenata na građanima vidljivom mjestu zbog čega je 2020. Zakonom o izmjenama i dopunama zakona o lokalnoj i regionalnoj samoupravi uvedena ta obveza (vidi [12], Čl.68.a).

Na primjer, za 2019. traženi dokumenti su navedeni u Tablica 2.1.

1.	Izvještaj o godišnjem izvršenju proračuna za 2018.
2.	Izvještaj o polugodišnjem izvršenju proračuna za 2019.
3.	Prijedlog proračuna za 2020.
4.	Izglasani proračun za 2020.
5.	Proračunski vodič za građane za 2020.

Tablica 2.1: Ključni proračunski dokumenti

Tih 5 dokumenata čini mjeru proračunske transparentnosti lokalnih jedinica – OLBI (***O**pen **l**ocal **b**udget **i**ndex*) – koja poprima vrijednost između 0 i 5, ovisno o broju objavljenih dokumenata na mrežnim stranicama lokalnih jedinica.

Naravno, sama objava ključnih proračunskih dokumenata ne znači apsolutnu transparentnost, no smatra se prvim korakom k višim razinama transparentnosti neophodnim za konstruktivno sudjelovanje građana u proračunskom procesu i kontroli prikupljanja i trošenja javnih sredstava. (vidi [21])

Podatke o razini proračunske transparentnosti objavljuje Institut za javne financije već duži niz godina te analizira proračunsku transparentnost svih hrvatskih županija, gradova i općina (vidi [21]).

Za razdoblje od 2015. do 2017., panel analizom pokazano je da hrvatske lokalne samouprave s većim dohotkom stanovnika po stanovniku, većim brojem stanovnika, boljim pristupom Internetu i većim fiskalnim kapacitetom objavljuju više proračunskih dokumenata (vidi [22]).

2.1.2. Proračunski ishodi

Financijski izvještaji lokalnih jedinica sadrže mnoštvo informacija. Nažalost, zbog njihovih detalja i formata građanima bez dodatne edukacije je često teško utvrditi financijsko stanje i učinak vlasti lokalnih jedinica iz tih podataka.

Kao posljedica toga, u radu se koristi financijski pokazatelj kako bi se odredila uspješnost lokalnih jedinica i regija, odnosno koje imaju bolji ili lošiji proračunski ishod. Uvodi se mjera proračunskih ishoda (tzv. mjera financijske uspješnosti ili financijski pokazatelj). (vidi [10])

Mjera proračunskih ishoda lokalnih jedinica je udio operativnog (poslovnog) viška/manjka u ukupnim operativnim (poslovnim) prihodima, a oznaka je $stor$ (***s**urplus/deficit in **t**otal **o**perating **r**evenues*). Ona pokazuje za koji se postotak poslovni prihodi razlikuju od poslovnih troškova.

$$stor_{it} = \left|\frac{tor_{it} - toe_{it}}{tor_{it}}\right| \cdot 100, i = 1, \dots, N, t = 1, \dots, T \tag{2.1}$$

tor ... ukupni operativni prihodi

toe ... ukupni operativni rashodi

i ... lokalna jedinica (N = 556)

t ... godina promatranja za razdoblje od 2014. do 2020.

Tumačenje mjere proračunskih ishoda:

Iako financijski pokazatelji inače pružaju snažnu procjenu financijske uspješnosti i održivosti, potrebno ih je tumačiti u kontekstu pojedine lokalne jedinice ili regije. Oni ne nadomještaju potrebu za razumnim prosuđivanjem. Kao i kod svakog kućanstva ili druge organizacije, dugoročna financijska održivost jedinice ovisi o tome da, u prosjeku tijekom vremena, njeni rashodi budu manji od prihoda.

Općenito, u prosjeku tijekom vremena, predloženi ciljni raspon za omjer operativnog viška je između 0% i 10%.

Naime, ako lokalna jedinica želi ciljati na vrlo veliki omjer operativnog viška, mora jasno artikulirati svoje razloge za to. Takav način djelovanja značio bi da bi lokalna jedinica određivala poreze i/ili druge naknade i naknade u iznosima koji su znatno veći od njezinih operativnih troškova. U skladu s tim, potrebno je pažljivo razmotriti utjecaj velikih operativnih viškova na međugeneracijsku pravednost.

Kada lokalna jedinica tijekom nekoliko godina posluje s velikim operativnim manjkom, a njeno strateško upravljanje i dugoročni financijski planovi ne daju jasne prijedloge za preokret, tada je neizbježno da se jedinica u budućnosti suoči s velikim financijskim šokovima.

Ako lokalna jedinica dosljedno postiže skroman udio $stor$ i ima utemeljena predviđanja koja pokazuju da to može nastaviti činiti i u budućnosti, uzimajući u obzir upravljanje imovinom i razinu usluga svoje zajednice, onda je financijski održiva. (vidi [15])

Hipoteza 1:

Lokalne jedinice s boljim proračunskim ishodima imaju višu razinu transparentnosti.

Smatra se da bolji proračunski ishodi povoljno utječu na razinu transparentnosti. To bi značilo da što je manja mjerna jedinica $stor$ lokalne jedinice to ona ima višu razinu transparentnosti. Pretpostavlja se da što je lokalna jedinica financijski uspješnija to će objavljivati više proračunskih dokumenata i voditi transparentniju politiku. Pozitivan odnos između veće proračunske transparentnosti i bolje proračunske učinkovitosti podnacionalnoj razini Turley et al. (vidi [28]), del Sol (vidi [8]) i Akhmedov i Zhuravskaya (vidi [1]). Koliko je poznato, postoji samo jedan rad koji izvještava o negativnoj korelaciji između transparentnosti i proračunskih ishoda (vidi [11]).

2.1.3. Direktni dug po stanovniku

Direktni dug županije, grada ili općine predstavlja zbroj svih proračunskih manjkova (deficita) iz tekućeg i ranijih razdoblja financiranih kratkoročnim i dugoročnim zaduživanjem (kreditima, zajmovima i izdavanjem vrijednosnih papira). Osim direktnog, postoji i potencijalni dug, kojeg čine jamstva koja su županije, gradovi i općine uglavnom izdala svojim trgovačkim društvima i ustanovama.

Prema Ott i Bronić (vidi [20]), ukupni direktni dug županija, gradova i općina RH se od 2002. do 2014. više nego udvostručio. Objavljivanje podataka o zaduženosti lokalnih jedinica neophodno je kako bi građani mogli procijeniti kvalitetu upravljanja županijama, gradovima i općinama.

Premda dug ne mora nužno biti nešto loše, pogotovo ako je uložen u investicijski projekt koji generira buduće društvene ili financijske koristi, važno je njime što bolje upravljati na svim razinama vlasti, posebice u vremenima rastućeg javnog duga.

Hipoteza 2:

Lokalne jedinice s višom razinom direktnog duga po stanovniku imaju višu razinu transparentnosti.

Pretpostavlja se kako viša razina direktnog duga po stanovniku potiče građane na reforme i veće zahtjeve prema lokalnoj jedinici, pa tako i prema transparentnijem sustavu. Pérez et. al (vidi [24]) otkrili su da postoji značajna veza između duga i objave financijskih izvještaja. Naime, kada dug postane visok te se pojave poteškoće postaje bitno objaviti financijske izvještaje koji pokazuju financijsku situaciju jedinice. Prema Styles i Tennyson (vidi [27]), gradovi s višom razinom duga po stanovniku imaju bolju dostupnost financijskim izvješćima koje sastavljaju vladine agencije.

2.1.4. Prihodi od poreza po stanovniku

Osnovni izvor financiranja lokalnih jedinica jest zakonom utvrđena podjela zajedničkih poreza između države i nižih razina vlasti (lokalnih jedinica), nakon čega slijede prihodi od pomoći te prihodi iz vlastitih i namjenskih prihoda sukladno posebnim propisima. (vidi [12])

Poslovne prihode lokalnih jedinica u prosjeku zadnjih pet godina, najviše su činili prihodi od poreza, zatim subvencije (pomoći, potpore iz inozemstva i od subjekata unutar općeg proračuna) te ostali prihodi, koje većinski čine prihodi od upravnih i administrativnih pristojbi, pristojbi po posebnim propisima i naknade (komunalne). (vidi Graf 2.1)

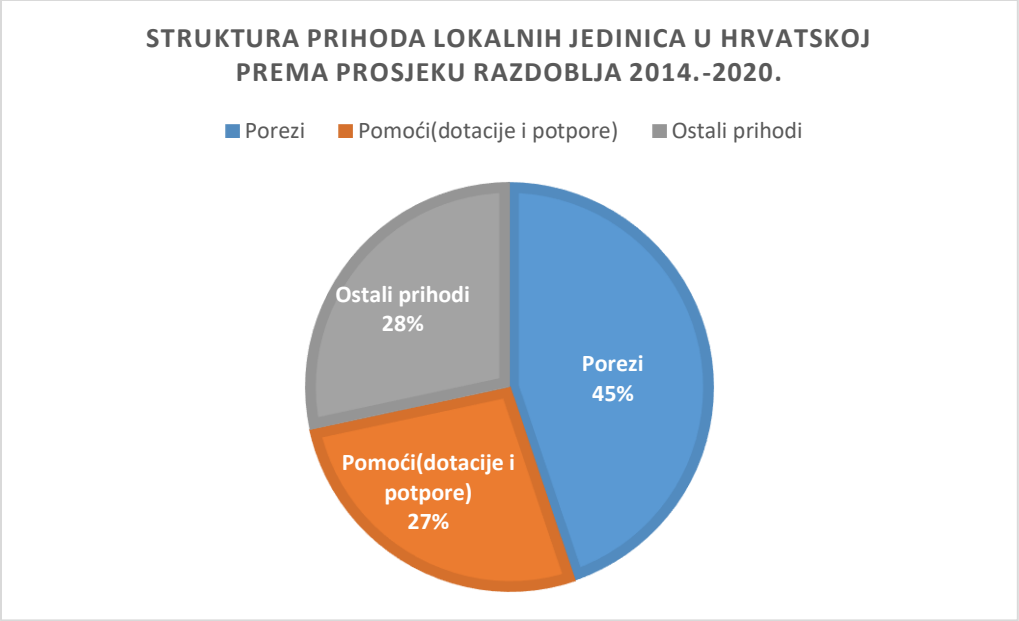

Graf 2.1: Struktura prihoda lokalnih jedinica u Hrvatskoj prema prosjeku razdoblja 2014.-2020.

S obzirom na to da je RH primjer fiskalno centralizirane zemlje, većina prihoda lokalne samouprave dolazi od poreza na dohodak koji je zajednički porez koji dijele središnja država i gradovi i općine. Štoviše, i regionalne i lokalne vlasti imaju vlastite porezne prihode (npr. prirez, porez na promet nekretninama itd.) koji zajedno čine većinu njihovih prihoda. (vidi [10])

Hipoteza 3:

Lokalne jedinice s većim prihodima od poreza po stanovniku imaju višu razinu transparentnosti.

Pretpostavlja se kako građani, kao porezni obveznici, zahtijevaju višu razinu proračunske transparentnosti ukoliko vlast uvodi veće poreze. Prema Guillamón, Bastida i Benito (vidi [16]) vrijedi da što su porezi veći, to je više financijskih informacija objavljeno, i sukladno tome, veća je transparentnost. To zapravo znači kako lokalne jedinice ne pribjegavaju fiskalnoj iluziji jer ne prikrivaju veće razine poreza od građana.

3. PODACI I METODOLOGIJA

U mnogim znanstvenim istraživanjima pokušava se utvrditi ovisi li neka odabrana veličina o drugim mjerenim veličinama. Veza između takvih mjerenja je vrlo rijetko jasna i deterministička, pa je najčešće predstavljamo koristeći vjerojatnosne modele.

Veličinu od interesa modeliramo kao slučajnu varijablu koju nazivamo ovisnom varijablom ili odzivom, Y, a sva ostala mjerenja, $X_1, \dots, X_d$, zovemo neovisnim varijablama, predviditeljima ili kovarijatama. Podatke koje želimo opisati tipično reprezentiramo kao niz uređenih parova

$$(y_{i,}\boldsymbol{x_i}), \qquad i = 1, \dots, n \tag{3.1}$$

Gdje je y_i i-ta realizacija slučajne varijable Y_i čija razdioba ovisi o kovarijatama $\boldsymbol{x_i}$, gdje je $\boldsymbol{x_i} = \left(x_{i_1}, \dots, x_{i_d}\right)$, za d kovarijata. Kovarijate mogu biti proizvoljno velike dimenzije. (vidi [5])

Metoda koja proučava ovisnost između varijabli i predstavlja najčešće upotrebljavanu statističku metodu naziva se regresijska analiza.

U ovom radu koristi se Poissonov linearni regresijski model unutar okvira generaliziranih linearnih modela jer ovisna varijabla koja opisuje razinu transparentnosti poprima nenegativne diskretne vrijednosti.

3.1. PODACI

Ovisna varijabla u ovom radu je razina transparentnosti proračuna, dok su nezavisne varijable proračunski ishodi, direktni dug po stanovniku i prihodi od poreza po stanovniku. U Tablica 3.1 prikazane su sve varijable koje se koriste u radu te njihovi izvori. Od sada nadalje koriste se skraćeni nazivi za varijable: OLBI umjesto proračunska transparentnost, STOR umjesto proračunski ishodi, DEBT umjesto direktnog duga po stanovniku i TAX umjesto prihodi od poreza po stanovniku.

Varijabla	Puni naziv	Izvor
OLBI	Indeks proračunske transparentnosti (OLBI)	Institut za javne financije
STOR	Proračunski ishodi	Ministarstvo financija
DEBT	Direktni dug po stanovniku	Ministarstvo financija
TAX	Prihodi od poreza po stanovniku	Ministarstvo financija

Tablica 3.1: Pregled svih varijabli

3.2. METODOLOGIJA - GENERALIZIRANI LINEARNI MODEL (GLM)

U prošlih nekoliko desetljeća linearni modeli oblika

$$y = X\beta + e \tag{3.2}$$

gdje se pretpostavlja da su elementi e nezavisni i jednako distribuirani s normalnom razdiobom $N(0, \sigma^2)$, činili su osnovu većine analiza neprekidnih podataka.

Napredak statističke teorije i računalnog softvera omogućio je korištenje metoda analognih onima razvijenim za linearne modele, uz manja ograničenja, tj. u idućim situacijama:

1. Kovarijate imaju distribuciju koja ne mora biti normalna distribucija, a može biti čak i kategorička.
2. Odnos između varijabli odziva i kovarijata ne mora biti jednostavnog linearnog oblika.

Jedan od tih napredaka bilo je prepoznavanje da mnoga „lijepa“ svojstva normalne distribucije dijeli i šira klasa distribucija koja se naziva eksponencijalna familija distribucija.

Drugi napredak bilo je proširenje numeričkih metoda za procjenu parametara, od linearnih kombinacija poput $X\beta$ iz formule (3.2) na funkcije linearnih kombinacija $g(X\beta)$.

U teoriji, postupci procjene su jednostavni. U praksi oni uključuju znatnu količinu računanja tako da su postali izvedivi tek s razvojem računalnih programa za numeričku optimizaciju nelinearnih funkcija. Oni su sada uključeni u mnoge statističke pakete. (vidi [9])

Postoji dobro utemeljena statistička teorija procjene parametara, ali i veliki broj radova i knjiga koje analiziraju primjenu GLM-a. Procjena parametara, kao i razni testovi za GLM-e uključeni su u komercijalne statističke pakete kao što su SAS, SPSS, Splus, Statistica, pa tako i R koji se koristi u ovom radu.

U idućim poglavljima navode se najpoznatije distribucije koje pripadaju eksponencijalnoj familiji distribucija i definiraju se generalizirani linearni modeli. (vidi [5] i [6]).

3.2.1. Eksponencijalne familije

Kaže se da slučajna varijabla Y pripada nekoj eksponencijalnoj familiji ako joj gustoća (neprekidna ili diskretna) ima oblik

$$f(y;\theta;\varphi) = \exp\left[\frac{y\theta - b(\theta)}{a(\varphi)} + c(y,\varphi)\right] \tag{3.3}$$

za neke funkcije a, b i c. Familija ima dva parametra: θ, tzv. prirodni parametar i φ, tzv. parametar disperzije ili skaliranja. Očekivanje od Y ovisi isključivo o parametru θ. U generaliziranom linearnom modelu dopušta se da θ ovisi o linearnoj kombinaciji kovarijata.

Bitne karakteristike gustoće (3.3.) su:

- Funkcija b u gornjoj definiciji je uvijek dvaput neprekidno diferencijabilna t.d. je b' invertibilna.
- Funkcija a parametra φ zove se funkcija disperzije, a omogućuje dodatnu fleksibilnost u modelu, tako da ne moraju svi odzivi imati istu varijancu. E.g. često pretpostavljamo $\varphi > 0$ jer predznak ne mijenja ništa bitno u obliku razdiobe.
- Funkciju c tipično ignoriramo jer nema utjecaja u procesu procjene parametara GLM – a.

Parametar θ ima vrijednosti u otvorenom skupu.

Jedan česti oblik funkcije disperzije je

$$a(\varphi) = \frac{\varphi}{w} \tag{3.4}$$

gdje je u praksi $w = w_i$ faktor težine i-tog opažanja, koji se često naziva izloženost. Izloženost omogućuje da se na relativno jednostavan način u model uvedu nejednake varijance.

Promotrimo funkciju log – vjerodostojnosti $l(y;\theta,\varphi) = \log(f(y;\theta,\varphi))$ unutar neke eksponencijalne familije. Ona je potrebna za procjenu GLM – a.

Pomoću slijedeća dva znana rezultata iz statističke teorije,

$$\mathbb{E}\left[\frac{\partial l}{\partial \theta}\right] = 0 \tag{3.5}$$

$$\mathbb{E}\left[\frac{\partial^2 l}{\partial \theta^2}\right] + \mathbb{E}\left[\left(\frac{\partial l}{\partial \theta}\right)\right] = 0 \tag{3.6}$$

dobiva se iznos varijance i iznos očekivanja slučajne varijable Y (koja pripada nekoj eksponencijalnoj familiji):

$$Var(Y) = a(\varphi)b''(\theta) \tag{3.7}$$

$$\mathbb{E}[Y] = b'(\theta) \tag{3.8}$$

gdje crtica označava derivaciju s obzirom na θ.

Dakle, očekivanje ne ovisi o φ, dok varijanca općenito ovisi o oba parametra.

Može se pokazati da je b' neprekidna i invertibilna (čak striktno rastuća funkcija) osim u trivijalnim egzotičnim slučajevima. Stoga stavljajući $\mu = b'(\theta)$ zapravo se uvodi novi parametar, tzv. <u>parametar srednje vrijednosti</u> (*mean value parameter*).

Naime sad je $\theta = b'^{-1}(\mu)$, pa je dobro defnirana <u>funkcija varijance</u> relacijom

$$\mu \mapsto V(\mu) = b''(\theta) = b''(b'^{-1}(\mu)) \tag{3.9}$$

Varijanca podataka ima dvije komponente: jednu koja uključuje parametar skaliranja, i drugu koja određuje način na koji varijanca ovisi o očekivanju. Da bi se naglasio utjecaj očekivanja na varijancu, varijanca se prikazuje kao

$$Var(Y) = a(\varphi)V(\mu) \tag{3.10}$$

3.2.2. Generalizirani linearni modeli (GLM)

Generalizirani linearni modeli su proširenje modela opće linearne regresije.

Općenito, osnovna ideja linearnih modela je pretpostavka da postoji linearna veza između očekivanja odziva i kovarijata,

$$\mathbb{E}Y_i = \sum_{j=1}^{d} \beta_i \, x_{i_j} \tag{3.11}$$

gdje je d broj mogućih kovarijata, $i = 1, \ldots, n$.

Često se pretpostavlja normalna distribuiranost odziva, $Y_i \sim N(\sum_{j=1}^{d} \beta_i \, x_{i_j}, \sigma^2)$.

Kod generaliziranih linearnih modela (GLM – a) prepostavlja se:

$$\mathbb{E}Y_i = g^{-1}\left(\sum_{j=1}^{d} \beta_i \, x_{i_j}\right), \qquad i = 1, \ldots, n \tag{3.12}$$

gdje je

- g^{-1}inverz tzv. funkcije veze g
- $\sum_{j=1}^{d} \beta_i \, x_{i_j}$ tzv. linearni prediktor s parametrom β kojeg je potrebno procijeniti
- za zadano očekivanje, Y_i ima unaprijed određenu razdiobu iz eksponencijalne familije.

Teorija GLM-a omogućuje simultano modeliranje ovisnosti varijable odaziva o numeričkim i kategorijalnim varijablama.

Iako slučajna komponenta odziva mora imati razdiobu iz neke od eksponencijalnih familija, ova restrikcija je u praksi često prihvatljiva jer te familije uključuju najčešće korištene razdiobe.

Dakle, pretpostavke generaliziranog linearnog modela manje su ograničene od onih općeg linearnog modela. Za razliku od opće linearne regresije gdje ovisna varijabla pripada normalnoj distribuciji, GLM dopušta da ovisna varijabla pripada bilo kojoj vjerojatnosnoj distribuciji iz eksponencijalne familije distribucija.

Generalizirani linerani model pretpostavlja da varijable odziva Y opažamo na nezavisan način za različite vrijednosti kovarijate x.

Model ima 3 komponente:

1. Sistemska komponenta:
   Kovarijate $\boldsymbol{x}$ koje mogu biti višedimenzionalne i na linearan način utječu na razdiobu od Y, preko tzv. <u>linearnog prediktora (predviditelja)</u> $\eta = \beta_1 x_1 + \cdots + \beta_d x_d$, gdje je $x = (x_1, \dots, x_d)$.
2. Slučajna komponenta:
   Razdioba slučajne varijable Y za dane kovarijate uvijek pripada istoj eksponencijalnoj familiji razdioba.
3. Veza između slučajne i sistemske komponente:
   Očekivanje od Y je glatka i invertibilna funkcija linearnog previditelja η oblika $b' \circ h$ za neku funkciju h, tj. označimo li

$$\theta = h(\eta) \tag{3.13}$$

zbog pripadnosti razdiobe slučajne varijable Y eksponencijalnoj familiji vrijedi

$$\mu = \mathbb{E}\mathrm{Y} = b'(\theta) = b'(h(\eta)) \tag{3.14}$$

$$\mu = g^{-1}(\eta) \tag{3.15}$$

za $g^{-1} = b' \circ h$, odnosno

$$\eta = g(\mu), \tag{3.16}$$

za funkciju $g = h^{-1} \circ b'^{-1}$ koju zovemo <u>funkcija veze</u>. Funkcija veze povezuje linearni predviditelj s očekivanom vrijednosti.

I prirodni parametar θ je u ovom slučaju glatka funkcija od η

$$\theta = b'^{-1}(\mu) = h(\eta). \tag{3.17}$$

Ako je $h \equiv id$, tada je $\eta \equiv \theta = b'^{-1}(\mu) = g(\mu)$, te se

$$g = b'^{-1} \tag{3.18}$$

naziva <u>kanonska</u> ili <u>prirodna</u> <u>funkcija veze</u>.

Općenito, utjecaj kovarijata na očekivanje odziva prikazuje dijagram:

$$(\boldsymbol{x}_i) \;\mapsto\; \eta_i = \beta_1 x_{i,1} + \cdots + \beta_d x_{i,d} \;\overset{h}{\rightarrow}\; \theta_i \;\overset{b'}{\rightarrow}\; \mu_i \tag{3.19}$$

Najpoznatije distribucije koje dolaze iz familije eksponencijalnih distribucija navedene su u Tablica 3.2 s pripadnim kanonskim funkcijama veze (link funkcijama). Nije nužno uvijek koristiti kanonske funkcije veze. One su izabrane zbog jednostavnosti.

Distribucija	Kanonska (prirodna) veza	Naziv
Normalna	μ	Identiteta
Binomna	$\log\left(\frac{\mu}{1-\mu}\right)$	Logit funkcija
Poissonova	$\log \mu$	Logaritam
Gama	$\frac{1}{\mu}$	Inverz

Tablica 3.2: Distribucije iz familije eksponencijalnih distribucija

3.2.1. Poissonova regresija

Poissonova regresija je oblik generaliziranog linearnog modela. Obično se koristi za regresijsku analizu podataka čija zavisna varijabla poprima nenegativne diskretne vrijednosti dobivene prebrojavanjem (*model for count data*).

Podatak o razini proračunske transparentnosti (OLBI) odabran je kao zavisna varijabla modela te poprima cjelobrojne vrijednosti od 0 do 5, stoga je za potrebe rada odabrana Poissonova regresija.

Dakle, pretpostavka modela je da zavisna slučajna varijabla ima Poissonovu razdiobu. Slučajna varijabla Y ima Poissonovu razdiobu s parametrom μ (srednja vrijednost prebrojavanja), ako za $\mu > 0$ poprima cjelobrojne vrijednosti $y = 0,1,2,3, \ldots$ s vjerojatnosti

$$\mathbb{P}(Y = y) = e^{-\mu} \frac{\mu^y}{y!} \tag{3.20}$$

Funkcija distribucije za Poissonovu razdiobu je $f(y) = e^{-\mu} \frac{\mu^y}{y!}$, a lako se prebaci u oblik (3.3):

$$f(y; \theta; \varphi) = \exp[y \log \mu - \mu - \log y!] \tag{3.21}$$

Gdje su funkcije i parametri:

Prirodni parametar: $\theta = \log \mu$

Parametar skaliranja: $\varphi = 1$, te zato i $a(\varphi) = 1$

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

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

Slijedi da su očekivanje i varijanca u Poissonovom modelu jednaki jer je $a(\varphi) = 1$:

$$\mathbb{E}\mathrm{Y} = b'(\theta) = e^{\theta} = \mu \tag{3.22}$$

$$\mathbb{E}Var(Y) = a(\varphi)V(\mu) = a(\varphi)b''(\theta) = e^{\theta} = \mu \tag{3.23}$$

Iz Poissonove distribucije izveden je Poissonov regresijski model uz pretpostavku da parametar μ ovisi o kovarijatama.

Prirodna ili kanonska funkcija veze je

$$g(\mu) = \eta = b'^{-1}(\mu) = \theta = \log \mu \tag{3.25}$$

stoga je ovisnost μ o kovarijatama dana s

$$\mathbb{E}[y_i|\boldsymbol{x_i}] = \mu_i = e^{\eta_i} = e^{x_i^T * \beta} = \exp(\beta_0 + \beta_1 x_1 + \cdots + \beta_d x_d) = Var(y_i|\boldsymbol{x_i}) \tag{3.26}$$

Osnovno svojstvo Poissonove regresije je jednakost uvjetnog očekivanja i uvjetne varijance. U literaturi se ono naziva svojstvom ekvidisperzije (*equidispersion*). Ukoliko jednakost ne vrijedi, odnosno vrijedi $\mathbb{E}[y_i|\boldsymbol{x_i}] < Var(y_i|\boldsymbol{x_i})$, kaže se da su podaci previše raspršeni (*overdispersion*).

Nakon odabira regresije, potrebno je procijeniti parametre modela β.

3.2.2. Procjena parametara

Procjena parametara u GLM može biti poprilično složena.

Standardna procedura za njihovu procjenu je MLE procedura tj. korištenje maksimuma funkcije vjerodostojnosti.

Nadalje je objašnjena metoda maksimalne vjerodostojnosti kojom se traži nepoznati parametar $\boldsymbol{\beta}$ u Poissonovom modelu. Sa y_i označava se i −to opažanje varijable odziva, dok je $\boldsymbol{x_i}$ oznaka za i −to opažanje nezavisnih varijabli (kovarijata). Navedene su funkcija gustoće Poissonove razdiobe i uvjetno očekivanje, respektivno.

$$f(Y_i = y_i|\boldsymbol{x_i}) = e^{-\mu_i}\frac{{\mu_i}^{y_i}}{y_i!} \tag{3.27}$$

$$\mathbb{E}[y_i|\boldsymbol{x_i}] = \mu_i = \exp(x_i^T\boldsymbol{\beta}) = \exp(x_1\boldsymbol{\beta_1}) \dots \exp(x_n\boldsymbol{\beta_n}) \tag{3.28}$$

Slijedi:

$$f(y_i|\boldsymbol{x_i},\boldsymbol{\beta}) = y_i \log(\mu_i) - \mu_i - \log y_i! = y_i\boldsymbol{x_i^T}\boldsymbol{\beta} - \exp\left(\boldsymbol{x_i^T}\boldsymbol{\beta}\right) - \log y_i! \tag{3.29}$$

Funkcija log – vjerodostojnosti za Poissonovu razdiobu je $l(\boldsymbol{\beta})$:

$$\begin{aligned} l(\boldsymbol{\beta}) = \log[L(\boldsymbol{\beta})] = \log\prod_{i=1}^{n} f(\,y_i|\boldsymbol{x_i},\boldsymbol{\beta}) = \sum_{i=1}^{n}\log(f(y_i|\boldsymbol{x_i},\boldsymbol{\beta})) \\ = \sum_{i=1}^{n}(y_i\boldsymbol{x_i^T}\boldsymbol{\beta} - \exp\left(\boldsymbol{x_i^T}\boldsymbol{\beta}\right) - \log y_i!) \end{aligned} \tag{3.30}$$

Deriviranjem funkcije log-vjerodostojnosti po $\boldsymbol{\beta}$ dobiva se uvjet preko kojeg se računa procjenitelj maksimalne vjerodostojnosti $\widehat{\boldsymbol{\beta}}$:

$$\sum_{i=1}^{n}(y_i - \exp\left(\boldsymbol{x_i^T}\boldsymbol{\beta}\right))\boldsymbol{x_i} = 0 \tag{3.31}$$

U praksi, osim za jednostavne modele, pronaći maksimume nije jednostavno i koriste se numerički algoritmi (Newton-Raphson ili iterative weighted least squares).

Interpretacija parametara Poissonove regresije ($\boldsymbol{\beta}$):

Neka je $\boldsymbol{\beta} = (\beta_1, \dots, \beta_d)$ vektor procijenjenih koeficijenata (parametara) Poissonove regresije. Prema jednakosti (3.28) promjena i-te varijable x_i vektora $\boldsymbol{X}$ za jednu jedinicu povećava/smanjuje (ovisno o predznaku β_i) uvjetno očekivanje $\mathbb{E}[Y|\boldsymbol{X}]$ i to $\exp(\boldsymbol{\beta_i})$ puta, uz uvjet da su sve ostale varijable nepromijenjene jer je:

$$\exp((x_i + 1)\boldsymbol{\beta_i}) = \exp(\boldsymbol{\beta_i}) * \exp(x_i). \tag{3.32}$$

Koliko precizno model procjenjuje nepoznatu vrijednost koeficijenata $\boldsymbol{\beta}$ mjeri se standardnom greškom procjene regresijskih koeficijenata. Što je greška manja, procjena je točnija.

Jasno je da bi model s proizvoljno mnogo parametara, odnosno kovarijata, mogao u teoriji postići savršenu predikciju očekivanih opaženih odziva, tj. riješiti sustav

$$y_i = g^{-1}(\eta_i) = g^{-1}(\beta_1 x_{i,1} + \cdots + \beta_d x_{i,d}) \tag{3.33}$$

Model u kojem je to moguće naziva se <u>zasićeni</u>. Usporedimo li naš procijenjeni model sa zasićenim modelom mogli bismo saznati koliko je on zaista dobar. Kako model s većim brojem parametara uključuje model s manjim brojem parametara kao svoj (restringirani) podmodel, ako njihove maksimizirane log-vjerodostojnosti označimo s $\hat{l}$, odnosno sa $\hat{l}_0$, vrijedi $\hat{l} \geq \hat{l}_0$, a obje vrijednosti su manje od $\hat{l}_F$ odnosno log-vjerodostojnosti zasićenog modela, $\hat{l}_F \geq \hat{l} \geq \hat{l}_0$.

3.2.3. Odabir modela

Uobičajena mjera koja se koristi kod testiranja Poissonovog regresijskog modela (ili, općenito, generaliziranog linearnog modela) jest devijanca.

<u>Devijanca</u>

Devijanca se definira kao mjera odstupanja opažene od očekivane vrijednosti dane modelom. Regresijski model devijancu uspoređuje sa zasićenim modelom (model koji postiže savršenu predikciju očekivanih opaženih odziva, tj. onaj za kojeg se postiže najveći mogući procjenitelj maksimalne vjerodostojnosti). Usporedimo li naš procijenjeni model sa zasićenim moglo bi se saznati koliko je procijenjeni model uistinu dobar.

Općenito, ako sa $\hat{l}$ označimo maksimiziranu log-vjerodostojnost koju smo postigli s našim procjeniteljima, a sa $\hat{l}_F$ maksimiziranu log-vjerodostojnost u zasićenom modelu, (skaliranu) devijancu definiramo kao:

$$d_M = 2(\hat{l}_F - \hat{l}) \tag{3.34}$$

Nakon procjene modela, odnosno procjene njegovih parametara važno je znati koje od kovarijata su zaista bitne u modeliranju odziva, a koje se mogu ispustiti.

Test omjera vjerodostojnosti (*likelihood ratio test*)

Da bi se odabrao model s bitnim kovarijatama, radi se test omjera vjerodostojnosti, a za njega se pretpostavlja iduće:

- Pretpostavka je da imamo p kontrolnih varijabli, tako da je linearni procjenitelj oblika

$$\eta = \beta_0 + \beta_1 x_1 + \cdots + \beta_p x_p. \tag{3.35}$$

- Pretpostavlja se i da se maksimiziranjem funkcije log-vjerodostojnosti pronašlo procjenitelje $\widehat{\beta_\iota}$ i dostigao se maksimum $\hat{l}$.
- Pretpostavlja se da želimo testirati nul hipotezu H_0: $\beta_{q+1} = \cdots = \beta_p = 0$, koja zapravo pretpostavlja da zadnjih $p - q$ kovarijata nije značajno te je bolje odabrati restringirani model nego puni model (ne mora biti zasićeni).

Procedura testa ima tri koraka:

1. Koristeći MLE procijenimo parametre u punom i restringiranom modelu.
2. Nađemo maksimalnu log-vjerodostojnost u punom i restringiranom modelu, odnosno, $\hat{l}_0$ i $\hat{l}$.
3. Izračuna se statistika omjera vjerodostojnosti (*log-likelihood ratio statistics*)

$$2(\hat{l} - \hat{l}_0) \tag{3.36}$$

Ako je ona iznad kritične vrijednosti za izabrani nivo značajnosti i razdiobu χ^2 sa $p - q$ stupnjeva slobode odbacuje se nul hipoteza. Tada se zaključuje da je puni model bolji od restringiranog.

Bitno je uočiti da je testna statistika zapravo razlika devijanci, tj.

$$2\left(\hat{l} - \hat{l}_0\right) = 2\left(\hat{l} - \hat{l}_F + \hat{l}_F - \hat{l}_0\right) = d_{M_0} - d_M \tag{3.37}$$

Velika vrijednost izraza (3.36) sugerira da promatrani model loše opisuje podatke u odnosu na puni model.

U R-u se za analizu devijance, kada su kovarijate dodavane u model određenim redoslijedom, koristi naredba anova(model), dok se dodatno, za p-vrijednost testa koristi anova(model, test='Chisq').[1]

Dakle, za usporedbu koliko su dva ugniježdena modela dobro prilagođena podacima koristi se test omjera vjerodostojnosti. U tu svrhu koristi se naredba u R-u anova(model1, model2, test='Chisq'), gdje je model1 ugniježđen u model2 (ili obratno), odnosno kovarijate odabrane u jednom modelu podskup su kovarijata odabranih za drugi model. Ako je dobivena razlika u devijancama veća od kritične vrijednosti, tada su dodani članovi značajni u objašnjenju varijacije u odzivu, odnosno odbacujemo nultu hipotezu da je model1 bolji od modela2.

U praksi se testovi često provode uz nivo značajnosti od 5%.

Null devijanca je pokazatelj koliko dobro osnovni NULL model (samo slobodni član) opisuje podatke. Rezidualna devijanca je pokazatelj koliko dobro predloženi model opisuje podatke. Promatranjem odnosa Null i rezidualne devijance može se ustanoviti je li prikladniji model koji ima samo slobodni član ili onaj model koji u sebi ima i parametar.

<u>Z-test</u>

Alternativno, za analizu značajnosti kovarijata mogu se promatrati i tzv. <u>Waldove z – statistike</u>

$$\frac{\widehat{\beta_i}}{s.e.(\widehat{\beta_i})} \tag{3.38}$$

gdje $s.e.(\widehat{\beta_i})$ predstavlja standardnu grešku procjene parametra β_i i provesti Z-test. Naime, uz nul – hipotezu $\beta_i = 0$ (utjecaj varijable x_i nije značajan) z – statistike bi aproksimativno trebale imati standardnu normalnu razdiobu prema Centralnom graničnom teoremu. Nul-hipoteza odbacuje se kad je z-vrijednost po apsolutnoj vrijednosti veća od $1.96 \approx 2$, odnosno kada je p-vrijednost manja od odabranog nivoa značajnosti (u ovom slučaju od 0.05). Ukoliko se nul-hipoteza odbaci, utvrđuje se da varijabla x_i ima statistilki značajan utjecaj na zavisnu varijablu y. Navedene z-vrijednosti i pripadajuće p-vrijednosti u R-u se ispisuju naredbom summary(model).

Postoje i automatizirane procedure zasnovane na tzv. AIC i sličnim kriterijima za odabir modela. Jedan način je traženje po svim mogućim modelima kako bi se pronašao model koji minimizira AIC, a to je tzv. metoda najboljeg podskupa (*all subsets regression*). Ta metoda nije izvediva za

[1] Prilikom odabira kovarijata metodom odabira unaprijed (forward selection) bitan je redoslijed kojim se uvode kovarijate u model.

probleme s velikim brojem podataka i puno varijabli. Dobra alternativa je korištenje postupne regresije (*stepwise regression*) koja će se u ovom radu provesti za svako modeliranje. (vidi [7])

Premda, procedure odabira varijabli treba koristiti s oprezom. Automatizirane procedure ne smiju biti zamjena za pažljivo razmatranje modela.

AIC

Akaike informacijski kriterij, skraćeno AIC, mjera je za usporedbu prilagođenosti dva ili više različitih regresijskih modela dobivenih istom metodom. AIC vrijednost računa se po formuli:

$$AIC = -2l + 2k \tag{3.39}$$

gdje je l funkcija log-vjerodostojnosti zasićenog modela , a k broj procijenjenih parametara, uključujući slobodni član.

Prema AIC kriteriju model koji najbolje opisuje podatke je onaj čija je AIC vrijednost najniža, iako to nije uvijek točno jer se smanjenjem broja parametara smanjuje i AIC, što se vidi i iz formule. Poznato je i da AIC ima sklonost odabrati model s prekomjernim brojem parametara (*overfitting*), osobito kod malih uzoraka, što zapravo treba izbjegavati. Koristi se za provjeru te usporedbu s modelom koji je odabran analiziranjem.

Funkcija koja se koristi u R-u za metodu odabira modela koji minimizira AIC pomoću postupne regresije (*stepwise regression*) je *stepAIC*, dok je za smjer (*direction*) procedure u ovom radu odabrana strategija postepenog odabira (*stepwise selection,* u R-u „*both*“) jer eliminira kovarijate koje imaju visoku korelaciju, tj. slično značenje.

Postoje tri strategije postupne regresije (*stepwise regression*) (vidi [7]):

Odabir unaprijed (forward selection), koji počinje bez prediktora u modelu, iterativno dodaje kovarijate koje najviše doprinose i zaustavlja se kada poboljšanje više nije statistički značajno.

Odabir unatrag (backward selection/elimination), koji počinje sa svim kovarijatama u modelu (puni model), iterativno uklanja kovarijate s najmanje doprinosa i zaustavlja se kada ima model u kojem su sve kovarijate statistički značajne. Uvjet je da je broj uzoraka, n, veći od broja kovarijata p.

Postepeni odabir (stepwise selection), koji je kombinacija odabira unaprijed i unazad. Počinje se bez prediktora, a zatimse uzastopno dodaju prediktori koji najviše doprinose (kao što je odabir

unaprijed). Nakon dodavanja svake nove varijable, uklone se sve varijable koje više ne pružaju poboljšanje prilagodbe modela (poput odabira unatrag).

Test disperzije

Ukoliko Poissonovo svojstvo jednake disperzije nije zadovoljeno, tj. kod modela je prisutna prekomjerna (*overdispersion*) ili premala disperzija (*underdispersion*) potrebno je odabrani model bolje prilagoditi podacima. U istraživanjima je uglavnom varijanca veća od očekivanja.

U radu se na kraju za odabrane modele provjerava postoje li naznake narušenosti svojstva disperzije pomoću testa preraspršenosti (disperzije) dostupnog u R-u naredbom dispersiontest(model, alternative='two.sided').

Nulta hipoteza je jednakost uvjetnog očekivanja i varijance. Ukoliko je nulta hipoteza odbijena, zaključak je da podaci nemaju svojstvo ekvidisperzije, ali moguće je bolje prilagoditi model podacima, npr. prebacivanjem na kvazi Poissonov model (u R-u: family='quasipoisson'), negativni binomni model (u R-u: family='negative.binomial()') ili procjenu određivanjem prva dva momenta.

U nastavku rada provodi se empirijska analiza u dva dijela: Deskriptivna statistika i Poissonova regresija.

4. EMPIRIJSKA ANALIZA

4.1. DESKRIPTIVNA STATISTIKA

Deskriptivna statistika je grana statistike koja se koristi pri opisivanju zadanog skupa podataka te njegovih statističkih obilježja.

Takva analiza korisna je radi boljeg razumijevanja podataka te uočavanja mogućih veza između varijabli koje se kasnije mogu primijeniti pri konstruiranju modela.

4.1.1. Deskriptivna statistika regija 2014.-2020.

Za razdoblje od 2014. do 2020. na panel podacima o svih šest regija napravljena je njihova usporedba s obzirom na proračunsku transparentnost i proračunske ishode.

<u>Proračunska transparentnost</u>

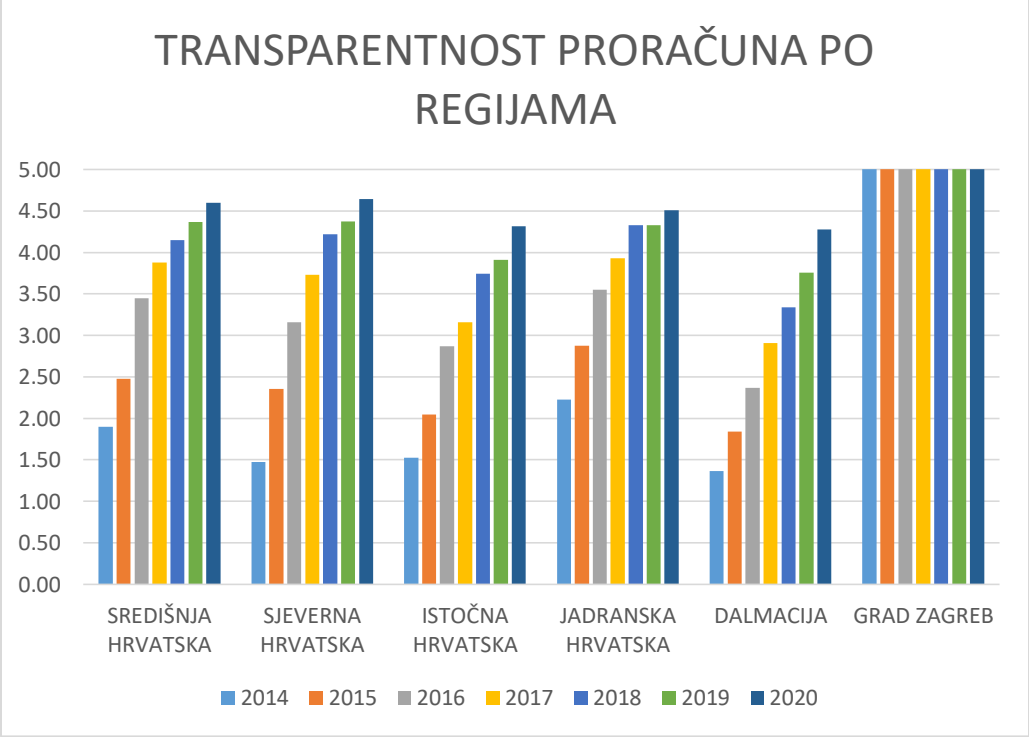

Graf 4.1: Transparentnost proračuna po regijama

Graf 4.1 prikazuje prosječnu transparentnost proračuna po regijama za razdoblje od 2014. do 2020. Očita stršeća vrijednost (*outlier*) je Grad Zagreb jer je svih sedam godina objavljivao svih 5 traženih dokumenata te postigao najveću moguću razinu transparentnosti.

U prosjeku ga redom slijede Jadranska Hrvatska i Središnja Hrvatska, dok su Sjeverna Hrvatska, Istočna Hrvatska i Dalmacija regije s prosječno najmanjom razinom transparentnosti. Poželjno je da sve lokalne jedinice godišnje obavijeste i educiraju svoje sugrađane o lokalnim proračunima, odnosno da sve imaju najvišu moguću razinu proračunske transparentnosti (5). Premda se u promatranom razdoblju vidi pozitivan trend i rast razine proračunske transparentnosti u svim regijama, 2019. su još uvijek lokalne jedinice u dvije regije (Istočna Hrvatska i Dalmacija) u prosjeku imale razinu proračunske transparentnosti ispod 4,00. Ipak, uspoređujući jako loše rezultate u 2014. i rezultate iz posljednje, 2020., razina proračunske transparentnosti znatno je porasla. Proces naglog rasta bio je vjerojatno ubrzan zbog tehnološkog napretka, digitalizacije i novih zakona.

<u>Proračunski ishodi</u>

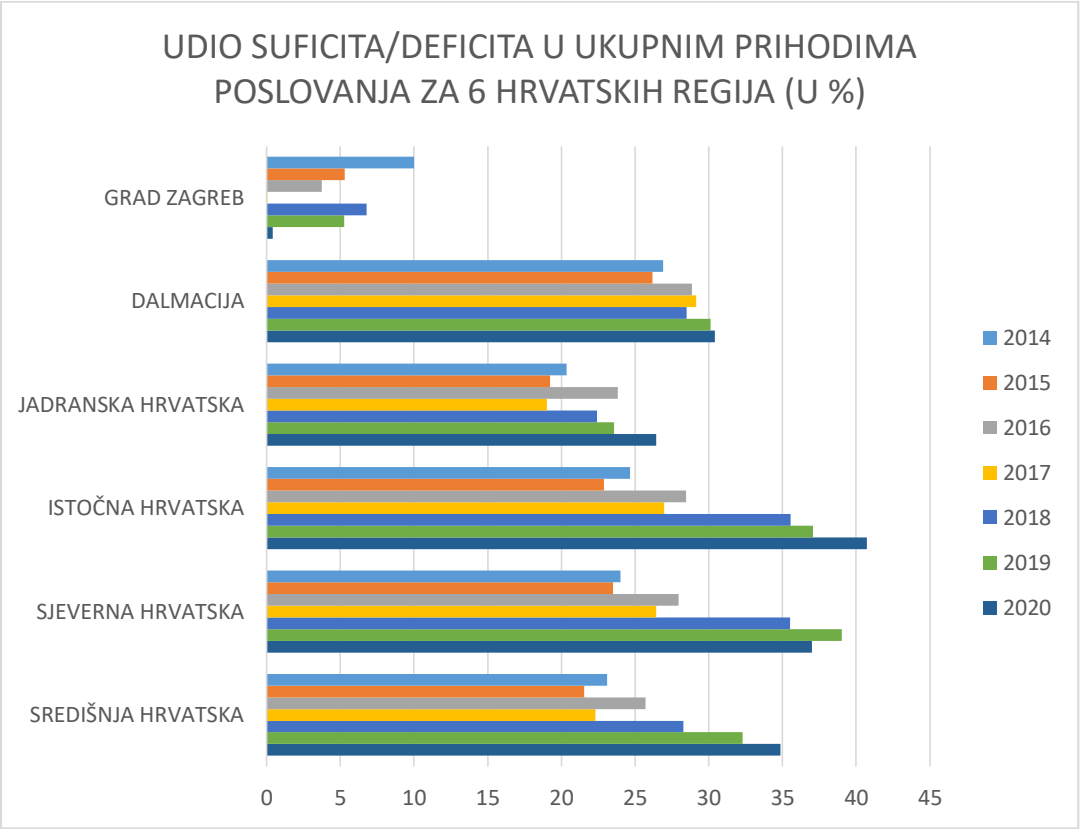

Graf 4.2: Udio suficita/deficita u ukupnim prihodima poslovanja za 6 hrvatskih regija (u%)

Graf 4.2 s podacima o udjelu viška/manjka u ukupnim poslovnim prihodima za šest hrvatskih regija u razdoblju od 2014. do 2020. upućuju na dva glavna zaključka. Prvo, Grad Zagreb ponovno je stršeća vrijednost (*outlier*) jer je njegov udio viška ili manjka u ukupnim poslovnim prihodima puno bolji od udjela preostalih pet regija te je svake godine bio unutar ciljnog raspona, između 0% i 10%.

Ponovno, ali u drugačijem poretku, prema prosjeku su Dalmacija, Sjeverna Hrvatska i Istočna Hrvatska regije koje imaju najlošije rezultate te negativan trend u promatranom razdoblju. Dok su preostale regije dosta daleko od cilja, Grad Zagreb je svih 7 godina bio unutar raspona. Detaljnije tumačenje mjere proračunskih ishoda navedeno je u potpglavlju 2.1.2.

Komparativna analiza šest hrvatskih regija upućuje na pretpostavku u skladu s Hipotezom 1, a to je da postoji blaga negativna korelacija između proračunskih ishoda i razine proračunske transparentnosti u tri hrvatske regije: Sjeverne Hrvatske, Dalmacije i Istočne Hrvatske.

4.1.2. Deskriptivna statistika regija 2017. i 2019.

Deskriptivna statistika varijabli regija posebno je provedena za 2017. i 2019. jer su to godine za koje je u idućem poglavlju provedena Poissonova regresija, dok je za Grad Zagreb napravljena deskriptivna statistika za cijelo razdoblje od 2014. do 2020. za varijable prihodi od poreza po stanovniku i direktni dug po stanovniku.

Nadalje su u jednostavnom tabličnom prikazu za preostale regije i za svaku varijablu izračunati minimum, medijan, aritmetička sredina i maksimum podataka.

Zatim je navedena i korelacijska matrica za svaku regiju (osim Grada Zagreba), dobivena Spearmanovim koeficijentom korelacije.

Naime, uz deskriptivnu statistiku uobičajeno je ispitivanje korelacije među varijablama. Korelacija je statistički postupak za izračunavanje povezanosti dviju varijabli. Vrijednost korelacije brojčano se iskazuje koeficijentom korelacije (ρ) koji pokazuje u kojoj su mjeri promjene vrijednosti jedne varijable povezane s promjenama vrijednosti druge varijable. Stoga su pronađeni koeficijenti korelacije ρ između parova nezavisnih varijabli i provedeni su testovi značajnosti s nultom hipotezom H_0: $\rho = 0$, u odnosu na alternativuH_1: $\rho \neq 0$. Između nekoliko uobičajenih tipova korelacije najčešće korištenih u statistici, koristi se Spearmanova korelacija jer ona ne zahtijeva nikakve pretpostavke o distribuciji podataka, varijable ne moraju biti u linearnom odnosu te nije osjetljiva na ekstremne rezultate.

Korelacijska matrica koristi se u poglavlju Poissonova regresija. Korelacija implicira da povezane varijable mjere slične stvari. Velika koreliranost među nezavisnim varijablama može narušiti točnost procijenjenog modela pa je bolje da ne idu u isti model.

<u>Grad Zagreb</u>

Grad Zagreb, glavni grad RH, ima status lokalne jedinice, županije i regije. Razinu proračunske transparentnosti već godinama održava na najvišem nivou stoga za njega Poissonova regresija nije provedena, već samo deskriptivni pregled varijabli korištenih u radu.

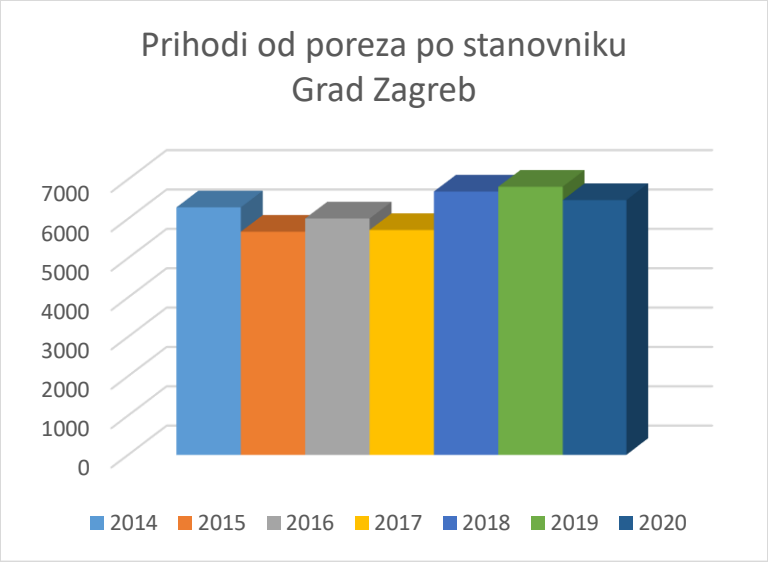

Graf 4.3: Prihodi od poreza po stanovniku, Grad Zagreb

Graf 4.3 prikazuje kretanje prihoda od poreza po stanovniku u Gradu Zagrebu koji je 2019. čak 20% viši nego 2015.

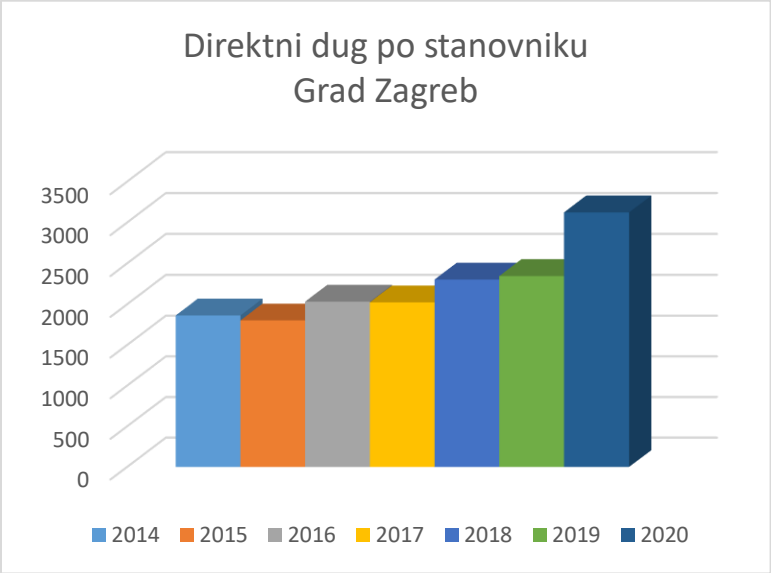

Graf 4.4: Direktni dug po stanovniku, Grad Zagreb

Graf 4.4 prikazuje kretanje direktnog duga po stanovniku u Gradu Zagrebu. Blagi rast direktnog duga po stanovniku naglo se promijenio 2020. kada je porastao za 33% s obzirom na prošlogodišnju vrijednost.

U nastavku su navedene deskriptivne karakteristike svih varijabli po regijama za 2017. i 2019. s ciljem boljeg razumijevanja podataka potrebnih za Poissonovu regresiju.

Deskriptivna statistika varijabli

Sjeverna Hrvatska

2017.

	OLBI	STOR	DEBT	TAX
Min.	0	0.1766	0	222.2
Median	4	25.2485	0	782.0
Mean	3.733	26.4360	344.5	832.0
Max.	5	57.1530	4580.1	2721.5

2019.

	OLBI	STOR	DEBT	TAX
Min.	1	4.169	0	1494
Median	5	39.331	0	2201
Mean	4.376	39.002	446.5	2198
Max.	5	122.883	4863.5	3286

Tablica 4.1: Deskriptivna statistika - Sjeverna Hrvatska

Lokalne jedinice u Sjevernoj Hrvatskoj 2017. imale su puno manje prihode od poreza po stanovniku nego 2019., dok prosječni direktni dug po stanovniku bilježi blagi porast. Medijan direktnog duga po stanovniku je 0 za obje godine, što znači da barem polovica lokalnih jedinica Sjeverne Hrvatske nije imala direktni dug.

Medijan razine proračunske transparentnosti (OLBI) 2017. je iznosio 4, što znači da je barem polovica lokalnih jedinica regije Sjeverna Hrvatska imala OLBI manji ili jednak 4, što se 2019. popravilo na 5.

Primijeti se i velika razlika s obzirom na prihod od poreza po stanovniku Grada Zagreba koji je za cca. 110% veći od najvećeg prihoda od poreza po stanovniku u Sjevernoj Hrvatskoj, čija vrijednost pripada Varaždinu 2017., te Grubišnom Polju 2019. (vidi Tablica 4.1)

Središnja Hrvatska

2017.

	OLBI	STOR	DEBT	TAX
Min.	0	0.5157	0	180.6
Median	4	21.2103	0	1125.6
Mean	3.879	22.2977	296.1	1194.8
Max.	5	51.7092	2080.4	3223.8

2019.

	OLBI	STOR	DEBT	TAX
Min.	1	4.569	0	1007
Median	5	30.888	85.87	2191
Mean	4.364	32.306	463.47	2309
Max.	5	70.712	4596.10	4269

Tablica 4.2: Deskriptivna statistika - Središnja Hrvatska

Tablica 4.2 pokazuje da lokalne jedinice u Središnjoj Hrvatskoj također bilježe porast svih varijabli uspoređujući podatke iz 2017. i 2019.

Za razliku od Sjeverne Hrvatske, 2019. medijan direktnog duga po stanovniku nije 0, što znači da je više od polovice lokalnih jedinica u regiji Središnja Hrvatska bilo zaduženo.

Istočna Hrvatska

2017.

	OLBI	STOR	DEBT	TAX
Min.	0	3.053	0	122.3
Median	3	26.818	0	582.7
Mean	3.157	26.976	205.6	640.7
Max.	5	63.181	3177.3	2108.7

2019.

	OLBI	STOR	DEBT	TAX
Min.	0	0.5213	0	615.7
Median	4	37.6958	0	2420.6
Mean	3.913	37.0876	308.5	2455.0
Max.	5	68.4047	5857	3555.6

Tablica 4.3: Deskriptivna statistika - Istočna Hrvatska

Lokalne jedinice u Istočnoj Hrvatskoj bilježe izrazito niže razine proračunske transparentnosti od prethode dvije regije. U 2017. i 2019. medijan direktnog duga po stanovniku je bio 0, što znači da barem polovica lokalnih jedinica Istočne Hrvatske nije imala direktni dug. Zapravo, za obje godine regija je imala najmanju srednju vrijednost direktnog duga po stanovniku od svih regija. (vidi Tablica 4.3)

Jadranska Hrvatska

2017.

	OLBI	STOR	DEBT	TAX
Min.	1	0.815	0	241.3
Median	4	17.208	419.7	2234.5
Mean	3.933	19.010	748.8	2393.4
Max.	5	48.520	5433.7	5786.1

2019.

	OLBI	STOR	DEBT	TAX
Min.	0	0.1498	0	1582
Median	5	22.5376	817.5	2828
Mean	4.326	23.5619	1168.6	3056
Max.	5	61.5770	6505.6	7358

Tablica 4.4: Deskriptivna statistika - Jadranska Hrvatska

Jadranska Hrvatska ističe se po niskoj prosječnoj vrijednosti mjere financijske uspješnosti $stor$ s obzirom na preostale regije (izuzev Grada Zagreba), što je pohvalno za lokalne jedinice te regije, po najvećoj razini direktnog duga po stanovniku, ali i po najvećim prihodima od poreza po stanovniku. Potonje se može objasniti i jako dobro razvijenim turizmom. (vidi Tablica 4.4)

Dalmacija

2017.

	OLBI	STOR	DEBT	TAX
Min.	0	1.146	0	148
Median	3	26.848	497.2	1576
Mean	2.908	29.132	497.2	1694
Max.	5	84.373	7623.8	6223

2019.

	OLBI	STOR	DEBT	TAX
Min.	0	1.209	0	404.5
Median	4	28.351	0	2633.8
Mean	3.756	30.113	670.4	2923.5
Max.	5	68.102	5988.6	7565.1

Tablica 4.5: Deskriptivna statistika - Dalmacija

Lokalne jedinice regije Dalmacija imaju najniže vrijednosti razine proračunske transparentnosti, visoke razine direktnog duga po stanovniku i vrlo visoke prihode od poreza po stanovniku. Potonje bi se ponovno moglo pripisati dobro razvijenom turizmu. (vidi Tablica 4.5)

Korelacijske matrice

Većina koeficijenata korelacije u ovom radu je vrlo niska, stoga će se za svaku regiju naglasiti samo najveće korelacije.

Sjeverna Hrvatska

2017.

	OLBI	STOR	DEBT	TAX
OLBI	1	-0.04	0.079	0.0028
STOR	-0.04	1	-0.155	-0.187
DEBT	0.079	-0.155	1	0.357
TAX	0.0028	-0.187	0.357	1

2019.

	OLBI	STOR	DEBT	TAX
OLBI	1	-0.047	0.112	-0.04
STOR	-0.05	1	-0.149	-0.002
DEBT	0.112	-0.149	1	0.0518
TAX	-0.04	-0.002	0.0518	1

Tablica 4.6: Korelacijska matrica - Sjeverna Hrvatska

Tablica 4.6 međusobnih korelacija pokazuje da sa zavisnom varijablom OLBI najviše korelira nezavisna varijabla DEBT, i to pozitivno. Ako se promatra koreliranost nezavisnih varijabli 2017. najviše koreliraju varijable DEBT i TAX, a 2019. STOR i DEBT.

Središnja Hrvatska

2017.

	OLBI	STOR	DEBT	TAX
OLBI	1	-0.115	0.3702	0.2852
STOR	-0.115	1	-0.218	-0.18
DEBT	0.3702	-0.218	1	0.452
TAX	0.2852	-0.18	0.452	1

2019.

	OLBI	STOR	DEBT	TAX
OLBI	1	-0.013	0.238	-0.193
STOR	-0.01	1	-0.119	0.0056
DEBT	0.238	-0.119	1	0.001
TAX	-0.19	0.0056	0.001	1

Tablica 4.7: Korelacijska matrica - Središnja Hrvatska

Tablica 4.7 međusobnih korelacija pokazuje da sa zavisnom varijablom OLBI najviše korelira nezavisna varijabla DEBT, i to pozitivno. Ako se promatra koreliranost nezavisnih varijabli 2017. najviše koreliraju varijable DEBT i TAX, a 2019. STOR i DEBT.

Istočna Hrvatska

2017.

	OLBI	STOR	DEBT	TAX
OLBI	1	0.0887	0.005	0.259
STOR	0.0887	1	-0.194	-0.189
DEBT	0.005	-0.194	1	0.304
TAX	0.259	-0.189	0.304	1

2019.

	OLBI	STOR	DEBT	TAX
OLBI	1	0.1657	0.1174	0.0068
STOR	0.1657	1	-0.231	-0.164
DEBT	0.1174	-0.231	1	-0.003
TAX	0.0068	-0.164	-0.003	1

Tablica 4.8: Korelacijska matrica - Istočna Hrvatska

Tablica 4.8 pokazuje da sa zavisnom varijablom OLBI najviše korelira nezavisna varijabla TAX, i to pozitivno. Promatrajući nezavisne varijable, 2017. najviše koreliraju varijable DEBT i TAX, a 2019. STOR i DEBT.

Jadranska Hrvatska

2017.

	OLBI	STOR	DEBT	TAX
OLBI	1	0.0997	0.1944	0.247
STOR	0.0997	1	-0.008	-0.003
DEBT	0.1944	-0.008	1	0.177
TAX	0.247	-0.003	0.177	1

2019.

	OLBI	STOR	DEBT	TAX
OLBI	1	-0.808	0.155	0.1381
STOR	-0.808	1	-0.031	0.0426
DEBT	0.155	-0.031	1	0.2319
TAX	0.1381	0.0426	0.2319	1

Tablica 4.9: Korelacijska matrica - Jadranska Hrvatska

Tablica 4.9 međusobnih korelacija pokazuje da sa zavisnom varijablom OLBI najviše korelira nezavisna varijabla TAX, i to pozitivno. Ako se promatra koreliranost nezavisnih varijabli 2017. najviše koreliraju varijable DEBT i TAX, a 2019. STOR i DEBT.

Dalmacija

2017.

	OLBI	STOR	DEBT	TAX
OLBI	1	-0.154	0.2624	0.2098
STOR	-0.154	1	-0.155	-0.087
DEBT	0.2624	-0.155	1	0.0764
TAX	0.2098	-0.087	0.0764	1

2019.

	OLBI	STOR	DEBT	TAX
OLBI	1	0.0276	0.0187	0.1446
STOR	0.0276	1	0.0471	0.037
DEBT	0.0187	0.0471	1	0.0626
TAX	0.1446	0.037	0.0626	1

Tablica 4.10: Korelacijska matrica - Dalmacija

Tablica 4.10 međusobnih korelacija pokazuje da sa zavisnom varijablom OLBI najviše korelira nezavisna varijabla DEBT, i to pozitivno. Ako se promatra koreliranost nezavisnih varijabli 2017. najviše koreliraju varijable STOR i DEBT, a 2019. TAX i DEBT.

4.2. POISSONOVA REGRESIJA

U ovom dijelu rada provodi se Poissonova regresija na način opisan u poglavlju Metodologija.

Pomoću R programa i naredbe glm() dobivaju se potrebni rezultati svakog modela za analizu: procijenjeni parametri β_i, vrijednost $\exp(\beta_i)$, standardna greška (s.e. – *standard error*) procjene parametra β_i, z-vrijednost Z-testa i njemu pripadajuća p-vrijednost, null devijanca, rezidualna devijanca sa stupnjevima slobode i AIC vrijednost.

Za svaku regiju bira se najbolji model, koji model ima manju AIC vrijednost, provjeravajući matricu korelacije, p-vrijednost i z-vrijednost, počevši od modela koji uključuje sve kovarijate.

Promatraju se i koeficijenti (β_i) nezavisnih varijabli te samim time utjecaj tih nezavisnih varijabli x_i na zavisnu varijablu, uz uvjet da ostale varijable ostanu nepromijenjene. Koeficijenti regresije β_i ukazuju koliki utjecaj promjena pojedine nezavisne varijable ima na kretanje zavisne varijable. Ukoliko je koeficijent pozitivan, porast nezavisne varijable dovodi i do porasta zavisne varijable, analogno vrijedi i obratno.

Pomoću testa omjera vjerodostojnosti, opisanog u poglavlju Metodologija, određuje se značajnost kovarijata, uspoređuju se modeli te njihova prilagođenost podacima.

Svaki odabrani model provjerava se pomoću AIC automatizirane procedure u R-u, i to postupnom (*stepwise regression*) regresijompostupnog odabira (*stepwise selection*).

Iz dobivenih modela izvode se zaključci o utjecaju tri odabrane varijable (tax, debt i stor) na razinu transparentnosti lokalne jedinice u svakoj od 5 regija.

Za svaku regiju opisani su koraci u analizi modela s podacima iz 2017., dok je za 2019. naveden samo odabrani model, dobiven istom procedurom.

4.2.1. Sjeverna Hrvatska

Promatra se MODEL 1.1 koristeći podatke o lokalnim jedinicama koje pripadaju regiji Sjeverna Hrvatska iz 2017.

MODEL 1.1 sadrži sve varijable, odnosno promatra se utjecaj svih izabranih nezavisnih varijabli na zavisnu varijablu OLBI.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 STOR + \beta_2 DEBT + \beta_3 TAX) \tag{4.1}$$

Rezultati regresije dobiveni testiranjem MODELA 1.1 prikazani su u Tablica 4.11.

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	1.344e+00	1.756e-01	7.655	1.94e-14 ***
stor	-2.291e-03	3.977e-03	-0.576	0.565
debt	4.424e-05	6.993e-05	0.633	0.527
tax	2.027e-05	1.343e-04	0.151	0.880
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1				
Null deviance: 58.835 on 100 degrees of freedom				
Residual deviance: 57.927 on 97 degrees of freedom				
AIC: 377.23				

Tablica 4.11: Rezultati regresije za MODEL 1.1 - Sjeverna Hrvatska

Prema rezultatima regresije, procijenjeni parametri, premda su male vrijednosti, predznaka su koji odgovaraju postavljenim hipotezama: varijabla STOR negativno je povezana s varijablom OLBI, dok su TAX i DEBT pozitivno korelirane s varijablom OLBI. Međutim, ti utjecaji nisu statistički značajni zato što su sve tri p-vrijednosti vrlo velike, odnosno veće od statističke značajnosti od 5%. AIC vrijednost iznosi 377.23 te može koristiti prilikom odabira najboljeg modela.

Tablica 4.11 ukazuje i blizinu vrijednosti Null i rezidualne devijance, odnosno mala razlika među njima. Ta razlika bi trebala imati χ^2 razdiobu sa $p - q = 3$ stupnja slobode kako NULL model nebi bio bolji od punog modela prema testu omjera vjerodostojnosti.

Model 1: olbi ~ 1					
Model 2: olbi ~ stor + tax + debt					
	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	100	58.835			
2	97	57.927	3	0.90747	0.8236
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1					

Tablica 4.12: Test omjera vjerodostojnosti za MODEL 1.1 - Sjeverna Hrvatska

Međutim, prema rezultatima testa u Tablica 4.12 ne odbija se nulta hipoteza. P-vrijednost je velika, te se može zaključiti kako je NULL model prihvatljiviji od MODELA 1.1 na razini značajnosti od 5%.

Bez obzira na takav rezultat, radi se provjera MODELA 1.2 s 1 kovarijatom manje te MODELA 1.3 s 2 kovarijate manje.

Za MODEL 1.2 isključuje se varijabla TAX zbog najveće koreliranosti s preostalim kovarijatama (vidi Tablica 4.6.).

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 STOR + \beta_2 DEBT) \tag{4.2}$$

Rezultati regresije dobiveni testiranjem MODELA 1.2 navedeni su u Tablica 4.13.

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	1.364e+00	1.174e-01	11.617	<2e-16 ***
stor	-2.422e-03	3.883e-03	-0.624	0.533
debt	4.620e-05	6.854e-05	0.624	0.500
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
Null deviance: 58.835 on 100 degrees of freedom				
Residual deviance: 57.950 on 98 degrees of freedom				
AIC: 375.25				

Tablica 4.13: Rezultati regresije za MODEL 1.2 - Sjeverna Hrvatska

Ponovno, varijable STOR i DEBT ne utječu statistički značajno na varijablu odziva, OLBI. AIC vrijednost je pala na 375.25, čime se naslućuje da je MODEL 1.2 bolji od MODELA 1.1. Razlika Null i rezidualne devijance je ponovno vrlo mala.

Za idući model isključuje se varijabla STOR zbog veće koreliranosti varijable DEBT s varijablom OLBI i veće p-vrijednosti. (vidi Tablica 4.6)

MODEL 1.3 promatra utjecaj kovarijate DEBT na varijablu odziva OLBI.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 DEBT) \tag{4.3}$$

Rezultati regresije dobiveni testiranjem MODELA 1.3. prikazani su u Tablica 4.14:

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	1.300e+00	5.738e-02	22.652	<2e-16 ***
debt	4.886e-05	6.819e-05	0.717	0.474
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
Null deviance: 58.835 on 100 degrees of freedom				
Residual deviance: 58.340 on 99 degrees of freedom				
AIC: 373.64				

Tablica 4.14: Rezultati regresije za MODEL 1.3 - Sjeverna Hrvatska

Kovarijati DEBT smanjila se p-vrijednost u usporedbi s MODELOM 1.2, ali nedovoljno da bi se na razini značajnosti od 5% odbacila nulta hipoteza o neznačajnosti kovarijate. AIC vrijednost se također smanjila. Razlika Null devijance i rezidualne devijance je vrlo mala, stoga se vrši provjera je li NULL model značajniji od MODELA 1.3, i to testom omjera vjerodostojnosti.

Model 1: olbi ~ 1					
Model 2: olbi ~ debt					
	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	100	58.835			
2	99	58.349	1	0.49462	0.4819

Tablica 4.15: Test omjera vjerodostojnosti za MODEL 1.3 - Sjeverna Hrvatska

Iz Tablica 4.15 se može iščitati visoka p-vrijednost, što znači da se nulta hipoteza ne odbacuje, odnosno da je restringirani model, u ovom slučaju NULL model, bolji odabir od MODELA 1.3.

Za kraj modeliranja podataka iz Sjeverne Hrvatske vrši se provjera odabira modela automatiziranom procedurom *stepAIC*.

```
Start:  AIC=377.23
olbi ~ stor + debt + tax

       Df Deviance    AIC
- tax   1   57.950 375.25
- stor  1   58.260 375.56
- debt  1   58.314 375.62
<none>      57.927 377.23

Step:  AIC=375.25
olbi ~ stor + debt

       Df Deviance    AIC
- stor  1   58.340 373.64
- debt  1   58.389 373.69
<none>      57.950 375.25
+ tax   1   57.927 377.23

Step:  AIC=373.64
olbi ~ debt

       Df Deviance    AIC
- debt  1   58.835 372.14
<none>      58.340 373.64
+ stor  1   57.950 375.25
+ tax   1   58.260 375.56

Step:  AIC=372.14
olbi ~ 1

       Df Deviance    AIC
<none>      58.835 372.14
+ debt  1   58.340 373.64
+ stor  1   58.389 373.69
+ tax   1   58.661 373.96
```

Slika 4.1: Procedura stepAIC - Sjeverna Hrvatska

Automatizirana procedura testirala je iste modele te došla do istog zaključka kako **NULL model** najbolje opisuje podatke. (vidi Slika 4.1)

Zaključuje se kako varijable STOR, DEBT i TAX nemaju utjecaj na varijablu OLBI u regiji Sjeverna Hrvatska.

Dakle, podaci o razini proračunske transparentnosti regije Sjeverna Hrvatska iz 2017. ne mogu se opisati predloženim varijablama.

Isti, NULL model, dobiven je analognom procedurom za podatke iz 2019. o regiji Sjeverna Hrvatska.

4.2.2. Središnja Hrvatska

Promatra se MODEL 2.1 koristeći podatke o lokalnim jedinicama koje pripadaju regiji Središnja Hrvatska iz 2017.

MODEL 2.1 sadrži sve varijable, odnosno promatra se utjecaj svih izabranih nezavisnih varijabli na zavisnu varijablu OLBI.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 STOR + \beta_2 DEBT + \beta_3 TAX) \tag{4.4}$$

Rezultati regresije dobiveni testiranjem MODELA 2.1 prikazani su u Tablica 4.16.

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	1.307e+00	1.546e-01	8.454	<2e-16 ***
stor	-3.218e-03	4.106e-03	-0.784	0.433
debt	8.583e-05	9.979e-05	0.860	0.390
tax	7.601e-05	9.023e-05	0.842	0.400
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1				
Null deviance: 40.443 on 106 degrees of freedom				
Residual deviance: 37.042 on 103 degrees of freedom				
AIC: 384.4				

Tablica 4.16: Rezultati regresije za MODEL 2.1 - Središnja Hrvatska

Dobiveni procijenjeni koeficijenti β_i imaju jako niske vrijednosti, što znači da kada bi i imali statistički značajan utjecaj na varijablu odziva OLBI, taj utjecaj bi bio malen. U skladu s postavljenim hipotezama, kovarijate DEBT i TAX imaju pozitivnu korelaciju s OLBI, dok je varijabla STOR u ovom modelu negativno povezana s OLBI. Međutim, z-vrijednosti svih kovarijata su manje od 1.96, pa su p-vrijednosti svih kovarijata su prevelike te niti jedna kovarijata nema statistički značajan utjecaj na OLBI. AIC vrijednost koja će pomoći pri usporedbi s idućim modelom je 384.4.

U idućem podmodelu MODEL 2.2 izbačena je kovarijata STOR iz MODELA 2.1. zbog najniže korelacije s varijablom odziva OLBI (vidi Tablica 4.7) te najveće p-vrijednosti u MODELU 2.1.

MODEL 2.2 sadrži sve kovarijate osim STOR.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 DEBT + \beta_2 TAX) \tag{4.5}$$

Rezultati regresije dobiveni testiranjem MODELA 2.2 prikazani su u Tablica 4.17.

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	1.225e+00	1.147e-01	10.681	<2e-16 ***
debt	9.963e-05	9.839e-05	1.013	0.311
tax	8.179e-05	8.979e-05	0.911	0.362
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
Null deviance: 40.443 on 106 degrees of freedom				
Residual deviance: 37.659 on 104 degrees of freedom				
AIC: 383.01				

Tablica 4.17: Rezultati regresije za MODEL 2.2 - Središnja Hrvatska

Procijenjeni parametri i dalje su vrlo male vrijednosti, dok su p-vrijednosti prevelike da bi kovarijate bile statistički značajne. AIC vrijednost se smanjila na 383.12, čime se naslućuje da je MODEL 2.2 prikladniji od MODELA 2.1.

Kako bi se provjerilo koji model bolje opisuje podatke, MODEL 2.1 ili MODEL 2.2 koristi se test omjera vjerodostojnosti.

Model 1: olbi ~ stor + debt + tax					
Model 2: olbi ~ debt + tax					
	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	103	37.042			
2	104	37.659	-1	-0.61699	0.4322

Tablica 4.18: Test omjera vjerodostojnosti za MODEL 2.1 i MODEL 2.2

Prema rezultatima danima u Tablica 4.18 p-vrijednost je velika stoga se ne odbacuje nulta hipoteza (restringirani model je bolji od punog modela) na razini značajnosti od 5%, tj. MODEL 2.2 bolje opisuje podatke od MODELA 2.1.

Idući model za analizu je MODEL 2.3 koji sadrži samo kovarijatu DEBT, izbacuje se kovarijata TAX zbog manje koreliranosti s OLBI (vidi Tablica 4.7) i veće p-vrijednosti.

MODEL 2.3. promatra utjecaj kovarijate DEBT na varijablu odziva OLBI.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 DEBT) \tag{4.6}$$

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	1.314e+00	5.768e-02	22.790	<2e-16 ***
debt	1.308e-04	9.133e-05	1.354	0.152
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
Null deviance: 40.443 on 106 degrees of freedom				
Residual deviance: 38.476 on 105 degrees of freedom				
AIC: 381.83				

Tablica 4.19: Rezultati regresije za MODEL 2.3 - Središnja Hrvatska

Iz Tablica 4.19 iščitava se p-vrijednost kovarijate DEBT se dodatno smanjila, ali nedovoljno za statističku značajnost of 5%. Smanjila se i AIC vrijednost.

Preostaje testom vjerodostojnosti provjeriti je li MODEL 2.3 model koji najbolje opisuje zadani te AIC procedurom usporediti postupak i odabir modela.

Model 1: olbi ~ debt + tax					
Model 2: olbi ~ debt					
	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	104	37.659			
2	105	38.476	-1	-0.81779	0.3658

Tablica 4.20: Test omjera vjerodostojnosti za MODEL 2.2 i MODEL 2.3

U Tablica 4.20 uspoređuju se MODEL 2.2. i MODEL 2.3. P-vrijednost je velika, stoga se zaključuje da MODEL 2.3 bolje opisuje podatke regije Središnja Hrvatska od MODELA 2.2.

Međutim, promotri li se razlika Null devijance i rezidualne devijance u Tablica 4.19, dobiva se vrlo mala vrijednost. To znači kako bi se trebalo provjeriti je li NULL model bolji od MODELA 2.3. Dakle, testom omjera vjerodostojnosti (vidi Tablica 4.21), dobiva se kako je NULL model bez varijabli zaista prihvatljiviji od MODELA 2.3 zbog velike p-vrijednosti i nemogućnosti odbijanja nulte hipoteze (restringirani model bolje opisuje podatke od punog modela) na razini značajnosti od 5%.

Model 1: olbi ~ 1					
Model 2: olbi ~ debt					
	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	106	40.443			
2	105	38.476	-1	1.9664	0.1608

Tablica 4.21: Test omjera vjerodostojnosti za MODEL 2.3

Provjera odabira modela automatiziranom procedurom *stepAIC*:

Automatiziranom procedurom izbacivane su kovarijate po istom redoslijedu kao i ručnom analizom. Također je **NULL model** predložen kao model koji najbolje opisuje podatke, odnosno ukazuje na to da varijable STOR, DEBT i TAX nemaju utjecaj na varijablu OLBI u regiji Središnja Hrvatska. (vidi Slika 4.2)

Dakle, podaci o razini proračunske transparentnosti regije Središnja Hrvatska ne mogu se statistički značajno opisati predloženim varijablama, kao ni podaci o razini proračunske transparentnosti regije Sjeverna Hrvatska.

```
Start:  AIC=384.4
olbi ~ stor + debt + tax

       Df Deviance    AIC
- stor  1   37.659 383.01
- tax   1   37.742 383.10
- debt  1   37.764 383.12
<none>      37.042 384.40

Step:  AIC=383.01
olbi ~ debt + tax

       Df Deviance    AIC
- tax   1   38.476 381.83
- debt  1   38.653 382.01
<none>      37.659 383.01
+ stor  1   37.042 384.40

Step:  AIC=381.83
olbi ~ debt

       Df Deviance    AIC
- debt  1   40.443 381.80
<none>      38.476 381.83
+ tax   1   37.659 383.01
+ stor  1   37.742 383.10

Step:  AIC=381.8
olbi ~ 1

       Df Deviance    AIC
<none>      40.443 381.80
+ debt  1   38.476 381.83
+ tax   1   38.653 382.01
+ stor  1   39.165 382.52
```

Slika 4.2: Procedura stepAIC - Središnja Hrvatska

Isti, NULL model, dobiven je analognom procedurom za podatke iz 2019. o regiji Središnja Hrvatska.

4.2.3. Istočna Hrvatska

Promatra se MODEL 3.1 koristeći podatke o lokalnim jedinicama koje pripadaju regiji Istočna Hrvatska iz 2017.

MODEL 3.1 sadrži sve varijable, odnosno promatra se utjecaj svih izabranih nezavisnih varijabli na zavisnu varijablu OLBI.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 STOR + \beta_2 DEBT + \beta_3 TAX) \tag{4.7}$$

Rezultati regresije dobiveni testiranjem MODELA 3.1 prikazani su u Tablica 4.22. Za svaku varijablu dobivene su male procjene vrijednosti parametra β.

Kovarijata STOR ima pozitivan utjecaj na OLBI, jednako kao i kovarijata DEBT, što je u suprotnosti s hipotezama 1 i 3, ali nisu statistički značajne prema Z-testu jer im je p-vrijednost previsoka. Kovarijata TAX također ima malu vrijednost procijenjenog parametra β, međutim z-vrijednost po apsolutnoj vrijednosti iznosi više od 1.96, p-vrijednost iznosi manje od 0.05, tj. manja je od razine značajnosti od 5% pa TAX statistički značajno utječe na OLBI. AIC modela je 467.02.

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	0.7471045	0.1813838	4.119	3.81e-05 ***
stor	0.0044994	0.0040637	1.107	0.26820
debt	-0.0001465	0.0001343	-1.091	0.27535
tax	0.0004717	0.0001729	2.728	0.00638 **
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
Null deviance: 102.144 on 126 degrees of freedom				
Residual deviance: 94.589 on 123 degrees of freedom				
AIC: 467.02				

Tablica 4.22: Rezultati regresije za MODEL 3.1 - Istočna Hrvatska

Za izradu MODELA 3.2 izbacuje se kovarijata DEBT iz MODELA 3.1. Kovarijata TAX zasigurno ostaje zbog niske p-vrijednosti i statističke značajnosti u MODELU 3.1, dok je kovarijata DEBT postigla najveću p-vrijednost, puno manje je korelirana s varijablom odziva OLBI nego preostale kovarijate, ima i blagu korelaciju s kovarijatom TAX te je zato odabrana za eliminaciju (vidi Tablica 4.8).

MODEL 3.2 sadrži sve kovarijate osim TAX.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 STOR + \beta_2 TAX) \tag{4.8}$$

Rezultati regresije dobiveni testiranjem MODELA 3.2 prikazani su u Tablica 4.23.

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	0.7599443	0.1809371	4.200	2.67e-05 ***
stor	0.0049540	0.0040525	1.222	0.2215
tax	0.0003880	0.0001558	2.491	0.0127 *
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
Null deviance: 102.144 on 126 degrees of freedom				
Residual deviance: 95.848 on 124 degrees of freedom				
AIC: 466.28				

Tablica 4.23: Rezultati regresije za MODEL 3.2 - Istočna Hrvatska

STOR i TAX pozitivno su korelirani s razinom proračunske transparentnosti, OLBI, ali samo TAX ima pozitivan i statistički značajan utjecaj na OLBI, s razinom značajnosti od 5%. Procijenjeni parametri nisu se puno promijenili, ali p-vrijednost kovarijate TAX je porasla s obzirom na MODEL 3.1. AIC vrijednost se malo smanjila, 467.02 na 466.28.

Za usporedbu MODELA 3.1 i MODELA 3.2 koristi se test omjera vjerodostojnosti. Prema rezultatima danima u Tablica 4.24 p-vrijednost je velika te se zato ne odbacuje nulta hipoteza (restringirani model je bolji od punog modela) na razini značajnosti od 5%, tj. MODEL 3.2 bolje opisuje podatke od MODELA 3.1.

Model 1: olbi ~ stor + debt + tax					
Model 2: olbi ~ stor + tax					
	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	123	94.589			
2	124	95.848	-1	-1.259	0.2618

Tablica 4.24: Test omjera vjerodostojnosti za MODEL 3.1 i MODEL 3.2

Posljednji, treći model koji će se ispitati za Istočnu Hrvatsku je MODEL 3.3 u kojem će biti samo jedna kovarijata koja je imala najmanju p-vrijednost, TAX.

MODEL 3.3 sadrži samo kovarijatu TAX.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 TAX) \tag{4.9}$$

Rezultati regresije dobiveni testiranjem MODELA 3.3 prikazani su u Tablica 4.25.

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	0.9306167	0.1119462	8.313	<2e-16 ***
tax	0.0003332	0.0001483	2.247	0.0246 *
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1				
Null deviance: 102.144 on 126 degrees of freedom				
Residual deviance: 97.342 on 125 degrees of freedom				
AIC: 465.78				

Tablica 4.25: Rezultati regresije za MODEL 3.3 - Istočna Hrvatska

Kovarijata TAX ponovno statistički značajno utječe na varijablu odziva, OLBI s razinom značajnosti od 5%. AIC vrijednost je 465.78, što je malo manje od MODELA 3.2. Kako je MODEL 3.3. podskup MODELA 3.2, napravljena je usporedba testom omjera vjerodostojnosti (vidi Tablica 4.26) te se na razini značajnosti od 5% ne odbacuje nulta hipoteza, tj. **MODEL 3.3** se smatra prihvatljivijim od MODELA 3.2, odnosno najpogodnijim modelom.

Model 1: olbi ~ stor + tax					
Model 2: olbi ~ tax					
	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	124	95.848			
2	125	97.342	-1	-1.494	0.2216

Tablica 4.26: Test omjera vjerodostojnosti za MODEL 3.2 i MODEL 3.3

Za dodatnu provjeru napravljena je i automatizirana procedura stepAIC, što se može vidjeti na Slika 4.3 koja prikazuje kojim redoslijedom je algoritam izbacivao varijable te vrijednosti kriterija AIC u svakom koraku.[2] Procedura AIC algoritma provela je malo drugačiji redoslijed izbacivanja kovarijata nego ručna analiza. Međutim, model koji AIC procedura odabire isti je kao i MODEL 3.3 dobiven analizom, stoga zaključujemo da je **MODEL 3.3** najprihvatljiviji model za podatke Istočne Hrvatske.

```
Start:  AIC=467.02
olbi ~ stor + debt + tax

       Df Deviance    AIC
- stor  1   95.816 466.25
- debt  1   95.848 466.28
<none>      94.589 467.02
- tax   1  101.788 472.22

Step:  AIC=466.25
olbi ~ debt + tax

       Df Deviance    AIC
- debt  1   97.342 465.78
<none>      95.816 466.25
+ stor  1   94.589 467.02
- tax   1  102.126 470.56

Step:  AIC=465.78
olbi ~ tax

       Df Deviance    AIC
<none>      97.342 465.78
+ debt  1   95.816 466.25
+ stor  1   95.848 466.28
- tax   1  102.144 468.58
```

Slika 4.3: Procedura stepAIC - Istočna Hrvatska

Provjerava se još i svojstvo jednake disperzije (raspršenosti) podataka u odabranom modelu pomoću testa ekvidisperzije. Dobiva se p-vrijednost $7.685^{-6} < 0.05$ te se ne odbacuje nulta hipoteza o podacima jednake disperzije, tj. o jednakosti uvjetne varijance i uvjetnog očekivanja zavisne varijable. Dakle, na razini značajnosti od 5% zaključujemo kako su podaci u MODELU 3.3 jednako raspršeni te vrijedi glavno svojstvo Poissonove distribucije. Prema tome, Poissonova regresija je dobar izbor za modeliranje povezanosti odabranih varijabli.

Pomoću tog modela može se potvrditi hipoteza ovog rada, a to je da prihodi od poreza po stanovniku imaju statistički značajan pozitivan utjecaj na razinu proračunske transparentnosti u regiji Istočna Hrvatska koristeći podatke iz 2017.

[2] Za pomoć pri izbacivanju varijabli može se koristiti i funkcija u R-u *drop1*, pomoću koje se prati koliko se AIC vrijednost smanjuje izbacivanjem pojedinih varijabli.

Analognom procedurom modeliranja Poissonovom regresijom za podatke iz 2019. o regiji Jadranska Hrvatska dobiven je drugačiji zaključak i model. Naime, 2019. niti jedna kovarijata nije značajna te je odabrani model NULL model.

4.2.4. Jadranska Hrvatska

Promatra se MODEL 4.1 koristeći podatke o lokalnim jedinicama koje pripadaju regiji Jadranska Hrvatska iz 2017.

MODEL 4.1 sadrži sve varijable, odnosno promatra se utjecaj svih izabranih nezavisnih varijabli na zavisnu varijablu OLBI.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 STOR + \beta_2 DEBT + \beta_3 TAX) \tag{4.10}$$

Rezultati regresije dobiveni testiranjem MODELA 4.1. prikazani su Tablica 4.27.

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	1.175e+00	1.531e-01	7.671	1.71e-14 ***
stor	1.683e-03	4.608e-03	0.365	0.715
debt	3.267e-05	5.294e-05	0.617	0.537
tax	5.643e-05	4.976e-05	1.134	0.257
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1				
Null deviance: 37.061 on 88 degrees of freedom				
Residual deviance: 34.775 on 85 degrees of freedom				
AIC: 326.53				

Tablica 4.27: Rezultati regresije za MODEL 4.1 - Jadranska Hrvatska

Prema rezultatima regresije navedenim u Tablica 4.27, procijenjeni parametri su vrlo male vrijednosti te su svi pozitivni, što implicira da je i kovarijata STOR pozitivno povezana s varijablom OLBI, suprotno od postavljene hipoteze. Međutim, ti utjecaji nisu statistički značajni zato što su sve tri p-vrijednosti vrlo velike, odnosno veće od statističke značajnosti od 5%. AIC vrijednost iznosi 326.53 te se može koristiti pri usporedbi s idućim modelom.

Idući MODEL 4.2 dobiven je iz MODELA 4.1 izbacivanjem kovarijate STOR koja je najmanje korelirana s varijablom odziva OLBI (vidi Tablica 4.9)i ima najveću p-vrijednost.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 DEBT + \beta_2 TAX) \tag{4.11}$$

U Tablica 4.28 se vide rezultati regresije dobiveni testiranjem MODELA 4.2.

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	1.203e+00	1.317e-01	9.137	<2e-16 ***
debt	3.294e-05	5.296e-05	0.622	0.534
tax	5.780e-05	4.984e-05	1.160	0.246
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
Null deviance: 37.061 on 88 degrees of freedom				
Residual deviance: 34.908 on 86 degrees of freedom				
AIC: 324.66				

Tablica 4.28: Rezultati regresije za MODEL 4.2 - Jadranska Hrvatska

Procijenjeni parametri i dalje su vrlo male vrijednosti, dok su p-vrijednosti prevelike da bi kovarijate bile statistički značajne. AIC vrijednost se smanjila na 324.66, čime se naslućuje da je MODEL 4.2 prikladniji od MODELA 4.1.

Kako bi se provjerilo koji model bolje opisuje podatke, MODEL 4.1 ili MODEL 4.2 koristi se test omjera vjerodostojnosti.

Model 1: olbi ~ stor + debt + tax					
Model 2: olbi ~ debt + tax					
	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	85	34.755			
2	86	34.908	-1	-0.13293	0.7154

Tablica 4.29: Test omjera vjerodostojnosti za MODEL 4.1 i MODEL 4.2

Prema rezultatima danima u Tablica 4.29 p-vrijednost je velika stoga se ne odbacuje nulta hipoteza (restringirani model je bolji od punog modela) na razini značajnosti od 5%, tj. MODEL 4.2 bolje opisuje podatke od MODELA 4.1.

Idući model za analizu je MODEL 4.3 koji sadrži samo kovarijatu TAX, izbacuje se kovarijata DEBT zbog manje koreliranosti s OLBI (vidi Tablica 4.9) i veće p-vrijednosti.

MODEL 4.3 promatra utjecaj kovarijate TAX na varijablu odziva OLBI.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 TAX) \tag{4.12}$$

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	1.211e+00	1.310e-01	9.246	<2e-16 ***
tax	6.493e-05	4.841e-05	1.341	0.18
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
Null deviance: 37.061 on 88 degrees of freedom				
Residual deviance: 35.288 on 87 degrees of freedom				
AIC: 323.04				

Tablica 4.30: Rezultati regresije za MODEL 4.3 - Jadranska Hrvatska

Iz Tablica 4.30 p-vrijednost kovarijate DEBT se dodatno smanjila, ali nedovoljno za statističku značajnost of 5%. Smanjila se i AIC vrijednost.

Preostaje testom vjerodostojnosti provjeriti je li MODEL 4.3 model koji najbolje opisuje zadani te AIC procedurom usporediti postupak i odabir modela.

Model 1: olbi ~ debt + tax					
Model 2: olbi ~ debt					
	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	86	34.908			
2	87	35.288	-1	-0.37984	0.5377

Tablica 4.31: Test omjera vjerodostojnosti za MODEL 4.2 i MODEL 4.3

U Tablica 4.31 se uspoređuju MODEL 4.2 i 4.3. P-vrijednost je velika, stoga se zaključuje da MODEL 4.3 (restringirani) bolje opisuje podatke regije Jadranska Hrvatska od MODELA 4.2 (puni).

Međutim, promotri li se razlika Null devijance i rezidualne devijance u Tablica 4.32, dobiva se vrlo mala vrijednost. To znači kako bi se trebalo provjeriti je li NULL model bolji od MODELA 4.3. Dakle, testom omjera vjerodostojnosti (Tablica 4.32), dobiva se kako je NULL model bez varijabli zaista prihvatljiviji od MODELA 4.3. zbog velike p-vrijednosti i nemogućnosti odbijanja nulte hipoteze (restringirani model bolje opisuje podatke od punog modela) na razini značajnosti od 5%.

Model 1: olbi ~ 1					
Model 2: olbi ~ tax					
	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	88	37.061			
2	87	35.288	1	1.7733	0.183

Tablica 4.32: Test omjera vjerodostojnosti za MODEL 4.3

Provjera odabira modela automatiziranom procedurom *stepAIC*:

```
Start:  AIC=326.53
olbi ~ stor + debt + tax

       Df Deviance    AIC
- stor  1   34.908 324.66
- debt  1   35.149 324.91
- tax   1   36.048 325.80
<none>      34.775 326.53

Step:  AIC=324.66
olbi ~ debt + tax

       Df Deviance    AIC
- debt  1   35.288 323.04
- tax   1   36.236 323.99
<none>      34.908 324.66
+ stor  1   34.775 326.53

Step:  AIC=323.04
olbi ~ tax

       Df Deviance    AIC
- tax   1   37.061 322.82
<none>      35.288 323.04
+ debt  1   34.908 324.66
+ stor  1   35.149 324.91

Step:  AIC=322.82
olbi ~ 1

       Df Deviance    AIC
<none>      37.061 322.82
+ tax   1   35.288 323.04
+ debt  1   36.236 323.99
+ stor  1   36.855 324.61
```

Slika 4.4: Procedura stepAIC - Jadranska Hrvatska

Automatiziranom procedurom izbacivane su kovarijate po istom redoslijedu kao i ručnom analizom. Također je **NULL model** predložen kao model koji najbolje opisuje podatke, odnosno ukazuje na to da varijable STOR, DEBT i TAX nemaju utjecaj na varijablu OLBI u regiji Jadranska Hrvatska. (vidi Slika 4.4)

Dakle, podaci o razini proračunske transparentnosti regije Jadranska Hrvatska ne mogu se statistički značajno opisati predloženim varijablama, kao ni podaci o razini proračunske transparentnosti regije Sjeverna Hrvatska i Središnja Hrvatska.

Isti, NULL model, dobiven je analognom procedurom za podatke iz 2019. o regiji Jadranska Hrvatska.

4.2.5. Dalmacija

Promatra se MODEL 5.1. koristeći podatke o lokalnim jedinicama koje pripadaju regiji Dalmacija iz 2017.

MODEL 5.1. sadrži sve varijable, odnosno promatra se utjecaj svih izabranih nezavisnih varijabli na zavisnu varijablu OLBI.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 STOR + \beta_2 DEBT + \beta_3 TAX) \tag{4.13}$$

Rezultati regresije dobiveni testiranjem MODELA 5.1 prikazani su u tablici

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	1.058e+00	1.375e-01	7.691	1.46e-14 ***
stor	-4.219e-03	3.369e-03	-1.252	0.2105
debt	7.016e-05	3.678e-05	1.908	0.0564 .
tax	5.195e-05	4.403e-05	1.180	0.2381
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1				
Null deviance: 162.99 on 130 degrees of freedom				
Residual deviance: 154.89 on 127 degrees of freedom				
AIC: 507.55				

Tablica 4.33: Rezultati regresije za MODEL 5.1 - Dalmacija

Iz Tablica 4.33 se vidi da su za svaku varijablu dobivene male procjene vrijednosti parametra β. Sve tri kovarijate prema predznacima parametara mogle bi potvrditi hipoteze ovog rada, ali ne mogu jer nisu statistički značajne prema Z-testu jer im je p-vrijednost previsoka. Jedino kovarijata DEBT ima z-vrijednost 1.908 koja je vrlo blizu 1.96, te joj p-vrijednost iznosi 0.0564, čime se naslućuje njena moguća statistička značajnost od 5%. AIC modela je 507.55.

Za izradu MODELA 5.2 izbacuje se kovarijata STOR iz MODELA 5.1. Kovarijata DEBT zasigurno ostaje zbog niske p-vrijednosti i statističke značajnosti od 10% u MODELU 5.1, dok je kovarijata STOR manje korelirana s varijablom odziva OLBI nego preostale kovarijate, više korelirana te je zato odabrana za eliminaciju (vidi Tablica 4.10).

MODEL 5.2 sadrži sve kovarijate osim STOR.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 DEBT + \beta_2 TAX) \tag{4.14}$$

Rezultati regresije dobiveni testiranjem MODELA 5.2 prikazani su u Tablica 4.34.

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	9.291e-01	9.338e-02	9.949	<2e-16 ***
debt	7.944e-05	3.597e-05	2.209	0.0272 *
tax	5.391e-05	4.366e-05	1.235	0.2169
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
Null deviance: 162.99 on 130 degrees of freedom				
Residual deviance: 156.47 on 128 degrees of freedom				
AIC: 507.14				

Tablica 4.34: Rezultati regresije za MODEL 5.2 - Dalmacija

DEBT i TAX pozitivno su korelirani s razinom proračunske transparentnosti, OLBI, ali samo TAX ima pozitivan i statistički značajan utjecaj na OLBI, s razinom značajnosti od 5%. Procijenjeni parametri nisu se puno promijenili, dok se AIC vrijednost malo smanjila, sa 507.55 na 507.14.

Za usporedbu MODELA 5.1 i MODELA 5.2 koristi se test omjera vjerodostojnosti. Prema rezultatima danima u Tablica 4.35 p-vrijednost je velika stoga se ne odbacuje nulta hipoteza (restringirani model je bolji od punog modela) na razini značajnosti od 5%, tj. MODEL 5.2 bolje opisuje podatke od MODELA 5.1.

Model 1: olbi ~ stor + debt + tax					
Model 2: olbi ~ debt + tax					
	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	127	154.89			
2	128	156.47	-1	-1.5886	0.2075

Tablica 4.35: Test omjera vjerodostojnosti za MODEL 5.1 i MODEL 5.2

Posljednji, treći model koji će se ispitati za Dalmaciju je MODEL 5.3. u kojem će biti samo jedna kovarijata koja je imala najmanju p-vrijednost, DEBT.

MODEL 5.3 sadrži samo kovarijatu DEBT.

$$\mathbb{E}[OLBI] = \exp(\beta_0 + \beta_1 DEBT) \tag{4.15}$$

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	1.020e+00	5.609e-02	18.18	<2e-16 ***
debt	8.483e-05	3.550e-05	2.39	0.0169 *
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
Null deviance: 162.99 on 130 degrees of freedom				
Residual deviance: 157.96 on 129 degrees of freedom				
AIC: 506.62				

Tablica 4.36: Rezultati regresije za MODEL 5.3 - Dalmacija

Rezultati regresije dobiveni testiranjem MODELA 5.3 prikazani su u Tablica 4.36. Kovarijata DEBT ponovno statistički značajno utječe na varijablu odziva, OLBI s razinom značajnosti od 5%. AIC vrijednost je 506.62, što je malo manje od MODELA 5.2

Kako je MODEL 5.3 podskup MODELA 5.2, napravljena je usporedba testom omjera vjerodostojnosti (vidi Tablica 4.37) te se na razini značajnosti od 5% ne odbacuje nulta hipoteza, tj. **MODEL 5.3.** se smatra prihvatljivijim od MODELA 5.2, odnosno najpogodnijim modelom.

Model 1: olbi ~ debt + tax					
Model 2: olbi ~ debt					
	Resid. Df	Resid. Dev	Df	Deviance	Pr(>Chi)
1	128	156.47			
2	129	157.96	-1	-1.484	0.2232

Tablica 4.37: Test omjera vjerodostojnosti za MODEL 4.2 i MODEL 4.3

Za dodatnu provjeru napravljena je i automatizirana procedura stepAIC, što se može vidjeti na Slika 4.5.

```
Start:  AIC=507.55
olbi ~ stor + debt + tax

       Df Deviance    AIC
- tax   1   156.24 506.91
- stor  1   156.47 507.14
<none>      154.89 507.55
- debt  1   158.19 508.85

Step:  AIC=506.91
olbi ~ stor + debt

       Df Deviance    AIC
- stor  1   157.96 506.62
<none>      156.24 506.91
+ tax   1   154.89 507.55
- debt  1   159.98 508.65

Step:  AIC=506.62
olbi ~ debt

       Df Deviance    AIC
<none>      157.96 506.62
+ stor  1   156.24 506.91
+ tax   1   156.47 507.14
- debt  1   162.99 509.66
```

Slika 4.5: Procedura stepAIC - Dalmacija

Slika 4.5 prikazuje kojim redoslijedom je algoritam izbacivao varijable te vrijednosti kriterija AIC u svakom koraku. Procedura AIC algoritma provela je malo drugačiji redoslijed izbacivanja kovarijata nego ručna analiza. Međutim, model koji AIC procedura odabire isti je kao i MODEL 5.3 dobiven analizom, stoga zaključujemo da je **MODEL 5.3** najprihvatljiviji model za podatke o lokalnim jedinicama regije Dalmacija.

Provjerava se još i svojstvo jednake disperzije (raspršenosti) podataka u odabranom modelu pomoću testa ekvidisperzije. Dobiva se p-vrijednost $0.2598 > 0.05$ te se ne odbacuje nulta hipoteza o podacima jednake disperzije, tj. o jednakosti uvjetne varijance i uvjetnog očekivanja zavisne varijable.

Dakle, na razini značajnosti od 5% zaključujemo kako su podaci u MODELU 5.3 jednako raspršeni te vrijedi glavno svojstvo Poissonove distribucije. Prema tome, Poissonova regresija je dobar izbor za modeliranje povezanosti odabranih varijabli.

Pomoću tog modela može se potvrditi hipoteza ovog rada, a to je da prihodi od poreza po stanovniku imaju statistički značajan pozitivan utjecaj na razinu proračunske transparentnosti u regiji Dalmacija koristeći podatke iz 2017.

Analognom procedurom modeliranja Poissonovom regresijom za podatke iz 2019. o regiji Dalmacija dobiven je drugačiji zaključak i model. Naime, 2019. niti jedna kovarijata nije značajna te je odabrani model NULL model.

4.2.6. Usporedba rezultata iz 2017. i 2019.

Usporedimo li dobivene rezultate iz 2017. i 2019. dobivene pomoću Poissonove regresije vidimo da 2019. niti jedna od kovarijata (proračunski ishodi, direktni dug po stanovniku i porez po stanovniku) nema statistički značajan utjecaj na varijablu odziva, razina proračunske transparentnosti, u niti jednoj regiji.

S druge strane, koristeći podatke iz 2017., Poissonova regresija je u dvije regije dobila statistički značajne modele. Dobio se pozitivan statistički značajan utjecaj kovarijate direktni dug stanovniku (DEBT) na varijablu odziva razina proračunske transparentnosti (OLBI) u regiji Dalmacija te pozitivan statistički značajan utjecaj kovarijate porez po stanovniku (TAX) na OLBI u regiji Istočna Hrvatska. To su zapravo regije čije su lokalne jedinice te dvije godine (2017. i 2019.), kao i svake godine u razdoblju od 2014. do 2020., imale najnižu prosječnu razinu proračunske transparentnost (vidi Graf 4.1.).

Provjerom i modeliranjem podataka Poissonovom regresijom za 2020., dobivaju se isti zaključci kao i za 2019. Suprotno tome, zanimljivi zaključci i statistički značajni utjecaji mogu se dobiti za podatke iz 2014. do 2017., korištenjem Poissonove regresije.

Zanimljivo je istaknuti kako statistički značajan utjecaj navedenih kovarijata na razinu proračunske transparentnosti s godinama nestaje.

Razlog tome može biti povećanje broja lokalnih jedinica koje objavljuju sve više podataka. Zato su razlike među njima sve manje, u kontekstu razine proračunske transparentnosti, a utjecaj se gubi.

Za podatke iz 2017. i 2019. napravljena je usporedba razine proračunske transparentnosti kako bi se ustanovilo je li razlika među njima statistički značajna, odnosno jesu li lokalne jedinice RH u prosjeku statistički značajno promijenile razinu proračunske transparentnosti.

Koristeći ponovno funkciju glm() u R-u i Poissonovu distribuciju promatra se utjecaj kovarijate godina (2017. ili 2019.) na varijablu odziva OLBI, razinu proračunske transparentnosti lokalnih jedinica.

	Estimate	Std. Error	z value	Pr(>|z|)
(Intercept)	1.24399	0.02277	54.637	< 2e-16 ***
god2019	0.17068	0.03091	5.522	3.36e-08 ***
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				

Tablica 4.38: Rezultati regresije - utjecaj kovarijate godina na OLBI

Iz dobivenih koeficijenata u Tablica 4.38 može se izračunati prosječna vrijednost razine proračunske transparentnosti za 2017. i za 2019., respektivno: $e^{1.24399} \approx 3.45$ i $e^{1.24399+0.17068} \approx 4.11$.

Iz Tablica 4.38 može se iščitati i vrlo niska p-vrijednost zbog čega se nulta hipoteza odbacuje. Zaključak je da se razina proračunske transparentnosti statistički značajno povećala 2019. s obzirom na 2017.

5. ZAKLJUČAK

U ovom radu pokušalo se odrediti postoje li razlike ili sličnosti u proračunskim ishodima i proračunskoj transparentnosti hrvatskih regija. Dodatno, ispitalo se koje ekonomske varijable statistički značajno utječu na proračunsku transparentnost lokalnih jedinica u pojedinim hrvatskim regijama prema podacima iz 2017. i 2019. te su uspoređeni rezultati za te dvije godine. Korištena je podjela na regije definirana područnim uredima Porezne uprave (Sjeverna Hrvatska, Središnja Hrvatska, Istočna Hrvatska, Jadranska Hrvatska, Dalmacija i Grad Zagreb). Na temelju prethodnih radova slične tematike te teorijskih razmatranja, promatrao se utjecaj slijedećihi varijabli: proračunski ishodi, direktni dug po stanovniku te prihodi od poreza po stanovniku. Varijabla proračunski ishodi mjerena je pomoću udjela operativnog suficita/deficita u operativnim prihodima (u radu – STOR). Ciljni raspon te mjere je između 0% i 10%. Postavljene su hipoteze kako direktni dug po stanovniku i porezni prihodi po stanovniku pozitivno utječu na razinu proračunske transparentnosti, a varijabla proračunski ishodi negativno. Za mjeru razine proračunske transparentnosti lokalnih jedinica koristio se Indeks otvorenosti lokalnog proračuna (*Open Local Budget Index* – u radu OLBI) koji svake godine objavljuje Institut za javne financije na temelju pet proračunskih dokumenata objavljenih na mrežnim stranicama lokalnih jedinica. Mjera razine proračunske transparentnosti poprima vrijednosti od 0 do 5, gdje 0 označava minimalnu, a 5 maksimalnu transparentnost.

Deskriptivnom i komparativnom analizom panel podataka o lokalnim jedinicama podijeljenim u regije za razdoblje od 2014. do 2020. ustanovljeno je kako regije Sjeverna Hrvatska, Dalmacija i Istočna Hrvatska bilježe prosječno najnižu razinu transparentnosti i najlošije proračunske ishode, prema mjeri $stor$. Suprotno tome, Grad Zagreb je regija koja je svih godina jedina imala odlične proračunske ishode prema mjeri $stor$ te je imala najvišu moguću razinu proračunske transparentnosti. Iz tog razloga za Grad Zagreb nije provedena regresijska analiza.

Poissonovim regresijskim modelima, gdje je nezavisna varijabla bio OLBI, ustanovila su se dva statistički značajna modela koristeći podatke iz 2017. Dobio se pozitivan statistički značajan utjecaj kovarijate direktni dug po stanovniku (DEBT) na varijablu odziva razina proračunske transparentnosti (OLBI) u regiji Dalmacija te pozitivan statistički značajan utjecaj kovarijate porez po stanovniku (TAX) na OLBI u regiji Istočna Hrvatska. To su zapravo regije čije su lokalne jedinice u razdoblju od 2014. do 2020., imale najnižu prosječnu razinu proračunske transparentnosti. Godine 2019. niti jedna od kovarijata (proračunski ishodi, direktni dug po stanovniku i porez po stanovniku) nije imala statistički značajan utjecaj na varijablu odziva, razina proračunske transparentnosti, u niti jednoj regiji.

Ustanovljeno je kako statistički značajan utjecaj navedenih kovarijata na razinu proračunske transparentnosti s godinama nestaje. Razlog tome može biti povećanje broja lokalnih jedinica koje objavljuju sve više podataka. Pomoću Poissonove regresije pokazano je da se razina

proračunske transparentnosti statistički značajno povećala 2019. u usporedbi s 2017. Zaključak je bio kako razina proračunske transparentnosti hrvatskih lokalnih jedinica raste iz godine u godinu te se zato smanjuju razlike među njima, u kontekstu razine proračunske transparentnosti, a utjecaj se gubi.

Dakle, prema podacima iz 2017., porastom direktnog duga po stanovniku raste i proračunska transparentnost lokalnih jedinica u Dalmaciji. Viša razina direktnog duga po stanovniku potiče građane na reforme i veće zahtjeve prema lokalnoj jedinici, pa tako i prema transparentnijem sustavu. Kada dug postane visok te se pojave poteškoće postaje bitno objaviti financijske izvještaje koji pokazuju financijsku situaciju jedinice. S druge strane, u Istočnoj Hrvatskoj porastom prihoda od poreza po stanovniku raste i proračunska transparentnost lokalnih jedinica. Naime, građani, kao porezni obveznici, zahtijevaju višu razinu proračunske transparentnosti ukoliko vlast uvodi veće poreze. To zapravo znači kako lokalne jedinice ne iskorištavaju fiskalnu iluziju jer ne prikrivaju veće razine poreza od građana. Takvi rezultati su u skladu s postavljenim hipotezama te se podudaraju s rezultatima drugih autora.

Međutim, rezultate ovog rada treba uzeti s dozomdodatnog opreza. Naime, zavisna varijabla, razina proračunske transparentnosti, je manjkava iz razloga što joj je raspon jako malen, samo od nula do pet. Zato su s vremenom i razlike među jedinicama sve manje dok ne postaju neznatne. Kada bi se razina proračunske transparentnosti kvalitetnije te detaljnije mjerila, za što je potrebno puno više rada i vremena, rezultati ovakvog i sličnih istraživanja bili bi kvalitetniji.

Ubuduće bi se mogla provesti i panel analiza svih regija za razdoblje od 2014. do 2020. te bi se mogle promatrati i druge odrednice, poput fiskalnog kapaciteta i pristupa internetu, koje bi možda mogle imati statistički značajan utjecaj na razinu proračunske transparentnosti.

LITERATURA

[1] Akhmedov A., Zhuravskaya E. 2004. "Opportunistic Political Cycles: Test in a Young."

https://doi.org/10.1162/0033553042476206.

[2] Bajo A., Alibegović D.J. 2008. *Javne financije lokalnih jedinica vlasti.* Školska knjiga.

[3] Bajo A., Bronić M. 2007. "Procjene učinkovitosti modela fiskalnog izravnavanja u Hrvatskoj."

https://hrcak.srce.hr/file/18859.

[4] Bajo A., Primorac M., Sopek P., Vuco M. 2015. "Neto fiskalni položaj županija od 2011. do 2013." *Institut za javne financije.*

http://www.ijf.hr/upload/files/file/newsletter/94.pdf.

[5] Basrak B., Planinić H. 2020. "Generalizirani linearni modeli."

https://web.math.pmf.unizg.hr/nastava/finprakt/Materijali1920/GLM/GLM_Notes2.pdf.

[6] Basrak, B. 2016. "Generalizirani linearni modeli."

https://web.math.pmf.unizg.hr/~bbasrak/pdf_files/FinPrak/FPchap7.pdf.

[7] Bruce P., Bruce A. 2017. *Practical Statistics for Data Scientists.*

[8] del Sol, D.A. 2013. "The institutional, economic and social determinants of local government transparency."

https://www.tandfonline.com/doi/abs/10.1080/17487870.2012.759422.

[9] Dobson, A.J. 1990. *An introduction to generalized linear models.*

[10] Erjavec N., Jakšić S., Mačkić V. 2017. "What determines the fiscal success at a local level? The case of Croatian local government units."

https://doi.org/10.17535/crorr.2017.0018.

[11] Gerunov, A. 2016. "Financial Effects of Fiscal Transparency: A Critique."

https://www.researchgate.net/publication/289229752_Financial_Effects_of_Fiscal_Transparency_A_Critique.

[12] Hrvatski sabor. 2020. "Zakon o izmjenama i dopunama Zakona o lokalnoj i područnoj (regionalnoj) samoupravi." *Narodne novine.*

https://narodne-novine.nn.hr/clanci/sluzbeni/2020_12_144_2762.html.

[13] Institut za javne financije. 2015. "Fiskalni položaj županija - okrugli stol održan 27. veljače 2015." *Institut za javne financije.*

https://www.academia.edu/26893880/Reforma_Sustava_Lokalne_I_Regionalne_Samouprave_U_Republici_Hrvatskoj.

[14] Koprić, I. 2012. "Consolidation, Fragmentation, and Special Statuses of Local Authorities in Europe."

https://hrcak.srce.hr/file/192808.

[15] Local Government Association of South Australia. 2015. "Financial Indicators - Financial Sustainability - Information Paper 9."

https://www.lga.sa.gov.au/__data/assets/pdf_file/0028/472438/09-Financial-Indicators-2015.pdf.

[16] Guillamón M.-D., Bastida F., Benito B. 2015. "Fiscal transparency and the cost of sovereign debt."

https://doi.org/10.1177/0020852315574999.

[17] Mačkić, V. 2013. "Political budget cycles at the municipal level in Croatia."

https://hrcak.srce.hr/file/177022.

[18] Mačkić, V. 2015. "Utjecaj političara i birača na političko- proračunski ciklus."

https://www.bib.irb.hr/970741.

[19] Ott K., Bajo A. 2001. "Lokalne financije i lokalni proračuni u Hrvatskoj." *Institut za javne financije.*

http://www.ijf.hr/FTP/2001/3/bajo_ott.pdf.

[20] Ott K., Bronić M. 2016. "Zaduženost županija, gradova i općina od 2002.-2014." *Institut za javne financije.*

https://www.ijf.hr/upload/files/103.pdf.

[21] Ott K., Bronić M., Petrušić M., Stanić B., Prijaković S. 2020. "Proračunska transparentnost županija, gradova i općina: studeni 2019. - travanj 2020." *Institut za javne financije.*

http://www.ijf.hr/upload/files/119.pdf.

[22] Ott K., Mačkić V., Bronić M., Stanić B. 2018. "Determinants of voluntary online local budget transparency: A case study from Croatia."

https://hrcak.srce.hr/218811.

[23] Ott K., Mačkić V., Prijaković S. 2019. "Budget Outcomes and Political Accountability: The case of Eastern Croatia region." *Institut za javne financije.*

https://www.bib.irb.hr/1010226.

[24] Pérez C.C., López Hernández A., Rodríguez Bolívar M.P. 2005. "Citizens' access to on-line governmental financial information: Practices in the European Union countries."

https://doi.org/10.1016/j.giq.2005.02.002.

[25] Rašić Bakarić I., Šimović H., Vizek M. 2014. "Ekonomska uspješnost gradova u Hrvatskoj - statistička analiza."

https://hrcak.srce.hr/file/179596.

[26] Stanić, B. 2018. "Determinants of subnational budget/fiscal transparency: a review of empirical evidence." *Institut za javne financije.*

https://hrcak.srce.hr/file/310959.

[27] Styles A.K., Tennyson M. 2007. "The accessibility of financial reporting of u.s. municipalities on the internet."

https://www.emerald.com/insight/content/doi/10.1108/JPBAFM-19-01-2007-B003/full/html.

[28] Turley G., Robbins G., McNena S. 2015. "A Framework to Measure the Financial Performance of Local Governments."

https://www.researchgate.net/publication/273177557_A_Framework_to_Measure_the_Financial_Performance_of_Local_Governments.rad

DODATAK

Tablica: PODACI O REGIJAMA

NAZIV REGIJE (br.županija)	ŽUPANIJE	BR. LOK. JED.	BR. GRAD	POV. (km^2)	UDIO GRADOVA U REGIJI (%)	BROJ ST. (2011.)	BROJ ST. (2021.)	STOPA PADA BR.ST. (%)	GUSTOĆA NASELJENOSTI 2021. (BR.ST./km^2)
Grad Zagreb (1)	Grad Zagreb	1	1	641	100	792 875	769 944	2.9	1 201
Sjeverna Hrvatska (4)	Varaždinska Koprivničko-križevačka Bjelovarsko-bilogorska Međimurska	101	17	6379	16.8	525 785	470 083	10.6	73
Istočna Hrvatska (5)	Virovitičko-podravska Požeško-slavonska Brodsko-posavska Osječko-baranjska Vukovarsko-srijemska	127	22	12 486	17.3	806 192	669 781	16.9	53
Središnja Hrvatska (4)	Zagrebačka Krapinsko-zagorska Sisačko-moslavačka Karlovačka	107	28	12 383	26.2	775 215	675 293	12.9	54
Jadranska Hrvatska (3)	Primorsko-goranska Ličko-senjska Istarska	89	28	11 754	31.5	555 585	505 190	9.1	42
Dalmacija (4)	Zadarska Šibensko-kninska Splitsko-dalmatinska Dubrovačko-neretvanska	131	32	12 951	24.4	857 743	798 238	6.9	61
RH	21	556	127	56 594	-	4 313 395	3 888 529	9.8	69

SAŽETAK

Regionalne razlike prepoznate su kao jedna od prepreka vođenju zdrave ekonomske politike. Cilj ovog rada bio je proučiti razlike među regijama Republike Hrvatske (RH) koje su definirane područnim uredima Porezne uprave (Sjeverna Hrvatska, Središnja Hrvatska, Istočna Hrvatska, Jadranska Hrvatska, Dalmacija i Grad Zagreb) te razlike između lokalnih jedinica unutar svake regije u okviru proračunske transparentnosti i proračunskih ishoda. Ispitivala se i statistička značajnost utjecaja ekonomskih varijabli na proračunsku transparentnost lokalnih jedinica u pojedinim hrvatskim regijama. Proračunska transparentnost bila je izražena Indeksom otvorenosti lokalnih proračuna (*Open Local Budget Indeks - OLBI*). Deskriptivnom analizom ustanovljeno je kako regije Sjeverna Hrvatska, Dalmacija i Istočna Hrvatska bilježe prosječno najnižu razinu transparentnosti i najlošije proračunske ishode. Suprotno tome, Grad Zagreb je regija koja je svih godina jedina imala odlične proračunske ishode te najvišu moguću razinu proračunske transparentnosti. Poissonovim regresijskim modelima usporedili su se rezultati dobiveni iz podataka 2017. i 2019. Godine 2017. dobio se pozitivan statistički značajan utjecaj direktnog duga po stanovniku (DEBT) na razinu proračunske transparentnosti (OLBI) u Dalmaciji te pozitivan statistički značajan utjecaj poreza po stanovniku (TAX) na OLBI u Istočnoj Hrvatskoj. To su zapravo regije čije su lokalne jedinice u razdoblju od 2014. do 2020., imale najnižu prosječnu razinu proračunske transparentnosti. S druge strane, godine 2019. niti jedna od odabranih ekonomskih varijabli nije imala statistički značajan utjecaj na razinu proračunske transparentnosti, u niti jednoj regiji. Ustanovljeno je kako statistički značajan utjecaj odabranih ekonomskih varijabli na razinu proračunske transparentnosti s godinama nestaje. Razlog tome može biti povećanje broja lokalnih jedinica koje objavljuju sve više podataka. Pomoću Poissonove regresije pokazano je da se razina proračunske transparentnosti statistički značajno povećala 2019. u usporedbi s 2017. Zaključak je kako razina proračunske transparentnosti hrvatskih lokalnih jedinica raste iz godine u godinu te se zato smanjuju razlike među njima, u kontekstu razine proračunske transparentnosti, a utjecaj se gubi.

SUMMARY

Regional differences are recognized as one of the obstacles to conducting a sound economic policy. The aim of this work was to study the differences between the regions of the Republic of Croatia defined by the regional offices of the Tax Administration (Northern Croatia, Central Croatia, Eastern Croatia, Adriatic Croatia, Dalmatia and the City of Zagreb) and the differences between local units within each region within the framework of the budget transparency and budgetary outcomes. The statistical significance of the influence of economic variables on the budget transparency of local units in Croatian regions was also examined. Budget transparency was expressed by the Open Local Budget Index (OLBI). Through descriptive analysis, it was established that the regions of Northern Croatia, Dalmatia and Eastern Croatia record on average the lowest level of transparency and the worst budget outcomes. On the contrary, the City of Zagreb is the only region that has had excellent budget results and the highest possible level of budget transparency in all years. Poisson regression models were used to compare the results obtained from the data of 2017 and 2019. In 2017, there was a positive statistically significant impact of direct debt per capita (DEBT) on the level of budget transparency (OLBI) in Dalmatia, and a positive statistically significant impact of taxes per capita (TAX) on OLBI in Eastern Croatia. These are actually the regions in which local units had the lowest average level of budget transparency in the period from 2014 to 2020. On the other hand, in 2019, none of the selected economic variables had a statistically significant impact on the level of budget transparency in any region. It was found that the statistically significant influence of selected economic variables on the level of budget transparency disappears over the years. The reason for this may be the increase in the number of local units that publish more and more data. Using Poisson regression, it was shown that the level of budget transparency increased statistically significantly in 2019 compared to 2017. The conclusion was that the level of budget transparency of Croatian local units is increasing from year to year, and therefore the differences between them are decreasing, in the context of the level of budget transparency, and the influence is being lost.

ŽIVOTOPIS

Valerija Kesteli rođena je 15. studenog 1996. u Koprivnici. Nakon završetka Osnovne škole „Vladimir Nazor“ Križevci i Glazbene škole Alberta Štrige Križevci upisuje Prirodoslovno-matematičku gimnaziju Ivana Zakmardija Dijankovečkoga Križevci. Tijekom školovanja sudjelovala je na županijskim i državnim natjecanjima iz povijesti, francuskog jezika i latinskog jezika te na sportskim natjecanjima. 2015. upisuje preddiplomski sveučilišni studij Matematika na Matematičkom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu. Titulu sveučilišne prvostupnice matematike stječe 2018. kada upisuje diplomski sveučilišni studij Financijska i poslovna matematika na istom fakultetu. Za javne financije i problem transparentnosti zainteresirala se na predmetu Ekonomika javnog sektora koji je predavala prof.dr.sc. Katarina Ott. Trenutno je zaposlena u TIS Grupi.