

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Matematički odsjek

Anđelka Oroz

Odrednice proračunske transparentnosti hrvatskih županija, gradova i općina

Diplomski rad

Voditelj rada:
Prof.dr.sc. Katarina Ott

Zagreb, rujan 2017.

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. _____

*Zahvaljujem mentorici prof. dr. sc. Katarini Ott na strpljenju, pomoći i vodstvu.
Također zahvaljujem Heli i Anti bez kojih ovo studiranje ne bi bilo tako zabavno.
Na kraju najveću zaslugu za sve što sam postigla do sada pripisujem svojoj obitelji i
svom Denisu koji su uvijek bili uz mene i davali mi beskrajnu podršku u svim trenucima
i bez kojih sve ovo što sam do sada postigla ne bi bilo moguće. Hvala vam na
beskonačnom strpljenju, razumijevanju i ljubavi.*

Sadržaj

1	Uvod	1
2	Pregled empirijske i teorijske literature	3
2.1	Varijable	5
2.1.1	Političari izabrani u prvom krugu	5
2.1.2	Ljevica na vlasti	6
2.1.3	Koalicija na vlasti	6
2.1.4	Visoko obrazovani političari	6
2.1.5	Dob političara	7
2.1.6	Deficit/Suficit	7
3	Podatci i metodologija	8
3.1	Podatci	8
3.2	Generalizirani linearni model (GLM)	9
3.2.1	Poissonova regresija	10
3.2.2	Procjena parametara	11
3.2.3	Test prilagodbe podacima	12
3.2.4	Test disperzije	13
4	Empirijska analiza	14
4.1	Deskriptivna statistika	14
4.1.1	Deskriptivna statistika županija	14
4.1.2	Deskriptivna statistika gradova	16
4.1.3	Deskriptivna statistika općina	18
4.2	Poissonova regresija	20
4.2.1	Poissonova regresija županija	20
4.2.2	Poissonova regresija gradova	24
4.2.3	Poissonova regresija općina	31
5	Zaključak	37
	Literatura	38
	Sažetak	54
	Summary	55
	Životopis	56

1 Uvod

U ovom se radu ispituje utjecaj političkih, ekonomskih i socijalno-kulturoloških varijabli na proračunsku transparentnost hrvatskih županija, gradova i općina. Konkretno analizira se je li utjecaj odabranih varijabli na proračunsku transparentnost statistički značajan.

Odabrane nezavisne varijable promatrane u radu su (i) političari izabrani u prvom krugu, (ii) ljevica na vlasti, (iii) koalicija na vlasti, (iv) visokoobrazovani političari, (v) dob političara te (vi) deficit/ suficit.

Ukratko hipoteze koje su postavljene u radu su:

- Ako je političar izabran u prvom krugu očekuje se negativan utjecaj na transparentnost.
- Kada je ljevica na vlasti očekuje se povećanje transparentnosti.
- Očekivan je negativan utjecaj koalicije na vlasti na transparentnost.
- Očekuje se da će dob političara pozitivno utjecati na transparentnost.
- I naposljetku se očekuje da će deficit pozitivno utjecati na povećanje transparentnosti.

Varijable su odabrane pregledom empirijske i teorijske literature domaćih i stranih autora. Kako bi se utvrdilo vrijede li postavljene hipoteze 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.

U radu su promatrane jedinice lokalne i područne (regionalne) samouprave. Jedinice lokalne samouprave su općine i gradovi, a jedinice područne (regionalne) samouprave su županije. U Republici Hrvatskoj (RH) ustrojeno je 576 jedinica i to 428 općina, 127 gradova te 20 županija. Grad Zagreb, kao glavni grad ima poseban status i grada i županije. Nakon provedene Poissonove regresije jedinom statistički značajnom varijablom pokazala se ljevica na vlasti, koja ima pozitivan učinak na transparentnost općina.

Rad koji slijedi strukturiran je u četiri dijela. U prvom dijelu rada sadržan je empirijski i teorijski pregled literature domaćih i stranih autora.

U drugom je detaljno je objašnjena korištena metodologija. Zatim slijedi analiza dobivenih rezultata gdje je prvo prikazana deskriptivna statistika varijabli i gdje se testiraju korelacije proračunske transparentnosti i nezavisnih varijabli te nezavisnih varijabli međusobno. Za svaku razinu lokalnih (regionalnih) jedinica konstruirano je više modela s različitim brojem varijabli i različitim kombinacijama varijabli. Glavna misao vodilja pri konstruiranju modela je promatranje tablice korelacija koja ukazuje koje varijable, zbog visoke koreliranosti, ne bi trebale biti u istom modelu kako ne bi narušile statističku

značajnost varijabli. Zadnji dio rada je zaključak u kojem se nudi kratki osvrt na cijeli rad.

2 Pregled empirijske i teorijske literature

Zadnje desetljeće transparentnost proračuna jedna je od glavnih tema u području fiskalne politike. Ne postoji jedinstven način mjerenja transparentnosti. OECD ¹ je 2001. objavio „OECD Best Practice for Budget Transparency“ s ciljem pružanja potrebnih savjeta i alata zemljama članicama EU-a i OECD-a u svrhu povećanja proračunske transparentnosti i kako bi mogao pomoći procijeniti transparentnost proračuna. Organiziran je u tri dijela: navodi koje glavne dokumente tj. izvješća vlada treba objaviti i što oni trebaju sadržavati; opisuje potreban sadržaj izvješća, a odnosi se na financijske i nefinancijske informacije; ističe kako se dokumenti koriste u praksi s ciljem osiguranja njihove kvalitete. [6]

S političkog gledišta, pitanje transparentnosti proračuna odraz je vjerodostojnosti nositelja vlasti, koja ovisi o poticajima i institucijama odgovornim za transparentnost proračuna. Kada se promatraju hrvatske lokalne jedinice transparentnost proračuna okarakterizirana je kao predanost lokalnih predstavnika svome radu i u svrhu poboljšanja na nacionalnoj razini. Ministarstvo financija predložilo je pet ključnih dokumenata koje je svaka lokalna jedinica dužna objaviti, dok s druge strane Institut za javne financije godišnje ocjenjuje i nagrađuje najtransparentnije lokalne jedinice. [23]

Postoje dva teorijska pristupa transparentnosti proračuna. Prvi je poštivanje zakonskih prava (*rule-of-law-theory*) odnosno transparentnost treba izložiti javnosti i smatra da je transparentnost kamen temeljac javne politike. Drugi je teorija principala (*principal agent theory*) koja proizlazi iz ideje da se približe javnom sektoru s ciljem otkrivanja boljeg upravljanja javnim sektorom. Visoka transparentnost nužna je kako bi glasači mogli potaknuti vladu da kontrolira proračunske procese. Ako birači ne mogu ispravno procijeniti tok prihoda i rashoda u državnom proračunu političari mogu povećati potrošnju netom prije izbora kako bi ponovno bili izabrani. [12]

Takav način zavaravanja glasača naziva se fiskalnom iluzijom jer porezni obveznik (glasač) ne može procijeniti trošak javnih programa. Teorija fiskalne iluzije omogućuje političarima prikriti buduća porezna opterećenja i mogućnost povećanja njihove koristi od javnih rashoda. Objavljivanje informacija o proračunu trebalo bi biti simbol povjerenja i suvremenosti s ciljem prikazivanja dobre vlade i visokog stupnja transparentnosti. [24]

Političari skrivaju svoju neučinkovitost lošim izvješćivanjem. Ima nekoliko oblika fiskalne iluzije a neki od njih su složena porezna struktura, nejasnoće pri oporezivanju imovine, prikrivanje javnog duga. Fiskalna iluzija proizlazi iz nemogućnosti birača da procijene ukupne međuvladine potpore koje se dodjeljuju primjerice županijskoj vladi.

Iako je transparentnost postala popularna i sve prisutnija tema nema puno ulaganja u njeno provođenje. Dva su razloga za to, prvi je da je mjerenje transparentnosti izrazito složeno, a drugi da je teško prikupiti pouzdane podatke pa se moramo osloniti na široke procjene transparentnosti.

¹Organisation for Economic Co-operation and Development

Kako je proračun vrlo složen to omogućuje korupciju i prikrivanje stvarnog stanja unutar države. Nedostatak transparentnosti pozitivno je koreliran s korupcijom, a korupcija je jedan od najvećih problema zemalja u razvoju (tranzicijskih zemalja) među kojima je i Hrvatska, a to je jedna od najvećih prepreka gospodarskom razvoju. Zemlje u razvoju izložene su visokom stupnju rashoda na svim upravnim razinama, alarmantno velikom dugu i nestabilnoj političkoj situaciji. Nedostatak transparentnosti plodno je tlo za korupciju. Također naglašava se da je stupanj korupcije veći na lokalnoj, nego na nacionalnoj razini. Lokalne jedinice imaju puno veću diskreciju pri donošenju odluka i političari mogu ostvariti svoje interese koji nerijetko ne idu u korist blagostanja države i njenih građana. Što je odaziv birača manji mogućnosti za korupciju raste. [6]

Transparentnost je bitan faktor za učinkovitu političku kontrolu i praćenje javnog sektora, te pomaže društvu u boljem praćenju doprinosa vlade i rješavanju problema. Informacije o politici mogu pomoći budućoj vladi da na primjeru bivše vlade poboljša kvalitetu javnog sektora. [6]

Prema tome interes za transparentnošću raste jer transparentnost proračuna doprinosi boljoj državnoj financijskoj situaciji.

Postavljeno je vrlo važno pitanje. Postoji li zamjena za reformu političkog sustava koja će pomoći pri rješavanju trenutnih problema među kojima je upravljanje javnim rashodima i uklanjanje mogućnosti korupcije? Jačanjem proračunske transparentnosti olakšali bi upravljanje izdatcima i provedbu teških odluka u politici, a to bi vladu moglo nagnati da prihvati zadane mjere u svrhu smanjenja javnih izdataka. [6]

Niska transparentnost može povećati zbunjenost među biračima i smanjiti želje političara da budu fiskalno odgovorni. Političari nerijetko dvosmislenošću politike mogu zbuniti i racionalnog glasača, ali ne mogu zbuniti potpuno informiranog glasača[6].

Proces glasanja jako je bitan pri utvrđivanju tko i kada može utjecati na donošenje i izvršenje proračuna. Transparentnost je tu da glasači mogu pratiti proces glasanja i rad politike kako bi donijeli dobre odluke za boljitak javne ekonomije i smanjenje javnog duga.

Postoji nekoliko "trikova" koji mogu negativno utjecati na porezne obveznike i njihovu percepciju pri izborima nove vlade, a neki od njih su precijenjeni očekivani rast gospodarstva, podcjenjivanje budućih izdataka ili zadržavanje izvanproračunskih stavki. Proračunski trikovi negativno utječu na transparentnost i mogu ograničavati dugoročni ekonomski potencijal rasta. Štoviše trikovi dopuštaju vladi da izbjegava reforme vezane uz javne izdatke. [1]

Transparentnost proračuna omogućuje javno dostupne informacije o vladinim postupcima i transakcijama. Tri najbitnije karakteristike proračunske transparentnosti su sustavno i pravodobno objavljivanje svih podataka o proračunu, učinkovita uloga zakonodavstva koje će proučavati proračunska izvješća te omogućeno djelovanje građana preko medija i nevladinih organizacija.

Proračunska transparentnost omogućuje biračima bolje razumijevanje proračuna, tj. financijskog plana vlade, te procjenu stvarne učinkovitosti vlade. Također smanjuje asi-

metriju u informacijama među glasačima jer što više glasača zna i razumije proračunski proces to se političari mogu manje baviti raznim strategijama kako bi koristili financijski deficit i pretjerano trošenje za postizanje vlastitih ciljeva. [25]

Unatoč važnosti političkih obilježja moraju se razmotriti i druga relevantna obilježja u objašnjavanju transparentnosti vlade. Mnoge studije utvrdile su da sociodemografske varijable igraju bitnu ulogu u potražnji za boljom transparentnošću proračuna. [12]

Optimistično previđanje ključnih makroekonomske varijabli, strateško kreiranje proračunskih projekcija i planiranje korištenje viška proračuna i imaju jedan od glavnih učinaka na transparentnost. [1]

Manje lokalne jedinice povezane su s višom razinom korupcije. Lokalne jedinice imaju puno veću diskreciju pri donošenju odluka i tako političari mogu ostvariti svoje interese koji nerijetko ne idu u korist blagostanja države i njenih građana. Dok je god odaziv birača mali to su mogućnosti za korupciju više. Nađena je, ne previše značajna, ali negativna veza između veličine polupacije i proračunske transparentnosti. [1]

Zemlje s najvišom stopom transparentnosti su ujedno i jedne od ekonomski najrazvijenijih zemalja (visoka uspješnost gospodarstva pozitivno je korelirana s transparentnosti).

2.1 Varijable

Varijable koje mogu utjecati na transparentnost proračuna mogu se podijeliti u tri skupine:

1. političke (npr. promjena lokalnog političkog čelnika u odnosu na prethodne izbore, odaziv građana na zadnjim izborima i pobjednički postotak na izborima)
2. sociodemografske varijable (npr. broj stanovnika/gustoća naseljenosti, starost i spol, razina obrazovanja, računalna pismenost i udio kućanstava koje posjeduju računala),
3. fiskalne (npr. dohodak po stanovniku, deficit/suficit).

2.1.1 Političari izabrani u prvom krugu

Predizborno natjecanje ima pozitivan učinak na transparentnost proračuna. Veći izbor među političarima u predizbornoj kampanji znači da se moraju prilagoditi zahtjevima građana kako bi osvojili njihov glas. Tada dolazi do sve manjeg odstupanja u interesima glasača i političara. S druge strane visok stupanj političke konkurentnosti povećava dugoročni trošak za izabrane dužnosnike, dovodi do neispunjavanja predizbornih obećanja i tjera političare da pristanu na veće troškove. [10]

Manje transparentna vlada ulaže više sredstava u predizbornu kampanju nego u povećanje transparentnosti. Ako odnesu većinu u prvom krugu manje su motivirani za poboljšanje

transparentnosti jer su gotovo sigurni u svoju pobjedu, a ako imaju veliku konkurenciju željet će se približiti glasačima i tako pokazati viši stupanj transparentnosti od konkurencije. [10]

2.1.2 Ljevica na vlasti

Kada se promatra tko je na vlasti, desnica kojom se u aktualnom političkom životu označavaju uglavnom konzervativne struje unutar političkog spektra ili ljevica, a to je naziv koji se upotrebljava kako bi opisalo socijaldemokraciju i socijalni liberalizam. Po dosadašnjim istraživanjima smatra se da politička ljevica teži povećanju javnog sektora pa se time od njih i očekuje veća transparentnost. Transparentnost utječe na kvalitetu percepcije građana o političkim strankama i njihovim ideologijama. [9]

Političke ideologije su bitne u donošenju odluka za koga glasati, ali dostupnost informacija o lokalnoj vlasti mogla bi presuditi kod osvještenih građana. [12]

Kada bi se odaziv na izborima povećao poticao bi građane na raspravu o relevantnim pitanjima unutar države i poboljšao bi njihovu političku svijest. Vlada bi tada imala veći poticaj djelovati učinkovitije ako je svjesna da građani nadgledaju njihov rad i raspravljaju o njemu. [12]

2.1.3 Koalicija na vlasti

Broj političkih stranaka na vlasti također utječe na transparentnost. Snažna politička stranka poboljšava učinak decentralizacije pri pružanju javnih dobara i kvalitete vlasti. Velike koalicije suočavaju se s nižom razinom transparentnosti, dok vlada s većom parlamentarnom većinom ima veću razinu transparentnosti. [12]

2.1.4 Visoko obrazovani političari

Proračunska pravila su politička pravila jer ih političari kreiraju i provode. Unatoč tome postoje aktivne skupine građana koje imaju puno bolji pristup informacijama nego ranijih godina. Transparentnost ovisi o razini poticanja stručnjaka i političara da objave točne i potpune informacije. [10]

Vlada ima nizak poticaj za izdavanje jednostavnih, jasnih i transparentnih proračunskih dokumenata. Vlada treba uložiti velike napore u svrhu povećanja transparentnosti proračunima kako bi građanima i samom financijskom tržištu omogućila stvarnu i pravilnu procjenu svojih učinaka, te poboljšala i olakšala u procesu odlučivanja u izborima. Zato su potrebni visoko obrazovani političari koji su sposobni poboljšati stanje u zemlji.

2.1.5 Dob političara

Kod ove varijable nailazi se na problem nepovjerenja građana u mlade političare. Naročito u malim sredinama gdje je i populacija starija, oni će prije glas dati nekome tko i nije naročito dobar, ali je provjeren jer se boje rizika da na vlast ne bi došao netko još gori. [9]

2.1.6 Deficit/Suficit

Literatura potkrepljuje činjenicu da proračunska pravila i transparentnost proračunskog sustava mogu utjecati na javne rashode a time i na fiskalne rezultate. Ranije je spomenut pojam fiskalne iluzije po kojem glasači precjenjuju prednosti javne potrošnje i podcjenjuju tekuće i buduće porezne troškove. [6]

Transparentnost proračuna smanjuje asimetriju informacija među poreznim obveznicima jer što više razumiju i znaju o procesu proračuna to političari imaju manje prostora za strateško djelovanje i smanjuje im se mogućnost korištenja fiskalnog deficita za postizanje vlastitih ciljeva. [6]

Glasači ne vole povećanja poreza, pa će se usprotiviti političaru koji ih bude zagovarao. Unatoč tome istraživanja pokazuju da su veći porezi i novčani transferi povezani s višom razinom fiskalne transparentnosti jer porezni obveznici zahtjevaju višu razinu transparentnosti kao uvjet za dopuštanje vladi da prikuplja veliku količinu financijskih sredstava. [6]

Viša razina državnog duga pozitivno je korelirana s transparentnosti, dok je viša razina duga po glavi stanovnika vezana s nižom transparentnosti. Deficit motivira građane na reforme više nego kada nema duga. [6]

3 Podatci i metodologija

Kao što je ranije spomenuto u ovom se radu želi utvrditi postoji li veza između zavisne varijable (indeksa transparentnosti) i odabranih nezavisnih. Veza u ovakvim mjerenjima vrlo je rijetko jasna i deterministička, pa se najčešće objašnjava koristeći vjerojatnosne modele.

Veličina od interesa modelira se kao slučajna varijabla koja se naziva ovisnom varijablom ili varijablom odaziva, a sva ostala mjerenja zovu se neovisnim varijablama, predviditeljima ili kovarijatama.

Varijable koje se žele opisati prikazuju se kao niz uređenih parova

$$(y_i, x_i), i = 1, \dots, n \quad (1)$$

gdje je y_i realizacija slučajne varijable Y_i čija razdioba ovisi o kovarijatama x_i .

Najpoznatiji model za testiranje takvih slučajeva je linearna regresija. Linearna regresija ima veliku primjenu u praksi zbog tehničke jednostavnosti i dobrih statističkih svojstava. Linearna regresija se koristi kada se želi utvrditi postoji li linearna ovisnosti između zavisne slučajne varijable Y_i i jedne ili više nezavisnih varijabli x_i . Međutim kod linearne regresije postoje nedostaci jer veza između zavisne i nezavisne varijable je nerijetno nelinearna. Stoga će se koristiti Generalizirani linearni model.

3.1 Podatci

Kao što je ranije navedeno nezavisne varijable koje se koriste u radu su političar izabran u prvom krugu, ljevica na vlasti, koalicija na vlasti, visokoobrazovani političar na vlasti, dob političara te deficit/ suficit. One su nezavisne varijable, a transparentnost proračuna je zavisna varijabla. Varijablu transparentnosti izračunali su Ott, Bronić, Petrušić i Stanić, gdje se proračunska transparentnost svih lokalnih jedinica u RH (općina, gradova i županija) mjeri brojem ključnih proračunskih dokumenata objavljenih na njihovim službenim mrežnim stranicama, a to su godišnje izvršenje proračuna za 2015., polugodišnje izvršenje proračuna za 2016., prijedlog proračuna za 2017, izglasani proračun za 2016. i proračun za građane za 2017. Kao što je ranije spomenuto transparentnost se kreće u rasponu od 0 do 5. [23]

U tablici 1 prikazane su nezavisne varijable koje se koriste u radu

	Nezavisne varijable
Prvi krug	Političari izabrani u prvom krugu izbora
Ljevica	Ljevica na vlasti
Koalicija	Koalicija na vlasti
VOpol	Visoko obrazovani političari
Dpol	Dob političara
Def Suf	Deficit ili Suficit

Izvor: izrada autorice

Tablica 1: Popis svih nezavisnih varijabli koje se koriste u radu

Vrijednosti za varijablu "Političar izabran u prvom krugu" određene su promatranjem rezultate lokalnih izbora iz 2013. Promatrani su rezultati iz prvog i drugog kruga rezultata.

Vrijednosti za varijable "Ljevica na vlasti" i "Koalicija na vlasti" određene su promatranjem rezultate drugog kruga lokalnih izbora iz 2013.

Vrijednosti za varijable "Visoko obrazovani političari" i "Dob političara" određene su pretragom niza političkih stranica gdje su bile objavljene biografije političara na vlasti.

Varijabla "Suficit/Deficit" određene su razlikom prirodnog logaritma suficita i prirodnog logaritma deficita za 2014. a podatci su pronađeni na stranicama Državnog zavoda za statistiku.

3.2 Generalizirani linearni model (GLM)

Generalizirani linearni model je proširenje opće linearne regresije. Teorija GLM-a omogućuje simultano modeliranje ovisnosti varijable odaziva o numeričkim i kategorijalnim varijablama.

Korištenjem generaliziranog linearnog modela pretpostavke su manje ograničene nego u općem linearnom modelu. Za razliku od linearne regresije gdje opažena varijabla pripada normalnoj distribuciji, GLM dopušta da opažena varijabla može pripadati bilo kojoj vjerojatnosnoj distribuciji iz eksponencijalne familije distribucija. U praksi mnoge zavisne varijable poprimaju nenegativne cjelobrojne ishode kakva je i varijabla OLBI.

Kategorijalne varijable ne predstavljaju problem za linearne modele no mnoge varijable koje se susreću nisu normalno distribuirane ili veza između zavisne varijable i nezavisnih varijabli nije linearna. Takvi nedostaci mogu se riješiti korištenjem šire klase distribucija koje se nazivaju eksponencijalnom familijom distribucija.

GLM se sastoji od tri komponente:

1. Slučajna komponenta, koja kaže da je vjerojatnosna distribucija od Y iz eksponencijalne familije distribucija.

2. Sistemska komponenta koja je linearna funkcija nezavisnih varijabli regresije odnosno prediktora.
3. Veza između slučajne i sistemske komponente koju nazivamo funkcijom veze.

U proceduri GLM-a implementirano je šest distribucija s najčešće korištenim funkcijama veze (link funkcijama). Najpoznatije distribucije koje dolaze iz familije eksponencijalnih distribucija su Poissonova, Normalna i Binomna distribucija.

Distribucija	Vezna funkcija (link funkcija)	Prirodni parametar	c	d
Normalna distribucija	Identiteta	$\frac{\mu}{\sigma}$	$-\frac{\mu^2}{2\sigma^2} - \frac{1}{2}\log(2\pi\sigma^2)$	$-\frac{y^2}{2\sigma^2}$
Binomna distribucija	Logit, Probit	$\log\left(\frac{\pi}{1-\pi}\right)$	$n\log(1-\pi)$	$\log\binom{n}{y}$
Poissonova distribucija	Logaritamska, Identiteta, Korijen	$\log\theta$	$-\theta$	$-\log y!$

Izvor: izrada autorice

Tablica 2: Distribucije iz eksponencijalne familije sa pripadnim funkcijama veza

3.2.1 Poissonova regresija

Poissonova regresija oblik je generaliziranog linearnog modela, gdje se pretpostavlja da slučajna zavisna varijabla ima poissonovu razdiobu. Poissonova regresija obično se koristi kada slučajna varijabla ima nenegativne cjelobrojne vrijednosti. Očekivanje i varijanca su kod poissonove razdiobe jednaki, tako da nema potrebe ocjenjivati oba parametra. Poissonova razdioba potpuno je određena srednjom vrijednošću μ . To nam govori da ako su vrijednosti u prosijeku veće, one više i variraju.

Neka su Y_1, \dots, Y_n nezavisne slučajne varijable gdje Y_i označava broj događaja zabilježenih u promatranju za η_i za i -tu uzorak kovarijanata. Očekivana vrijednost od Y_i može se zapisati kao

$$E(y) = \mu_1 = n_i\theta_i \quad (2)$$

Ovisnost parametra θ o kovarijatima odnosno o varijablama objašnjenja se obično modelira jednadžbom

$$\theta_i = e^{x_i^T \beta} \quad (3)$$

Funkcija distribucije za Poissonovu razdiobu dana je sa

$$f(y) = \frac{e^{-\mu} \mu^y}{y!} \quad (4)$$

gdje je $y = 1, 2, \dots$ broj ponavljanja događaja i $\mu = E[Y]$ po definiciji.

Kod generaliziranog linearnog modela očekivanje je oblika

$$E(Y_i) = \mu_i = n_i e^{x_i^T \beta}; Y \sim Po(\mu_i) \quad (5)$$

Za Poissonovu regresiju potrebna je funkcija veze $g(\cdot)$ koja ograničena da μ poprima samo nenegativne vrijednosti i dopušta da nezavisne varijable, tj. prediktori poprime bilo koju vrijednost iz skupa realnih brojeva. Prirodan odabir bila bi logaritamska funkcija. Logaritamska funkcija uzima cjelobrojne vrijednosti kao ulazne i transformira ih u vrijednosti iz skupa realnih brojeva.

$$\log \mu_i = \log n_i + x_i^T \beta; \mu = \exp(\beta_0 + \beta_1 x_1 + \dots + \beta_n x_n) \quad (6)$$

3.2.2 Procjena parametara

Procjena parametara u GLM-u može biti poprilično složena. Standardna procedura za njihovu procjenu je metoda maksimalne vjerodostojnosti. U praksi, osim za jednostavne modele, nije jednostavno pronaći maksimume i koriste se numerički algoritmi (Newton-Raphson ili iterative weighted least squares).

Za neprekidne varijable objašnjenja x_k , promjena jedne jedinice nezavisne varijable rezultirat će eksponencijalno na očekivanu promjenu zavisne varijable, odnosno e^{β_k} pod uvjetom da sve ostale varijable ostanu nepromijenjene.

Testiranje hipoteza može se provesti testom prilagodbe modela nad procijenjenim vrijednostima.

Predviđene vrijednosti dane su

$$Y_i = \hat{\mu}_i = n_i e^{x_i^T \beta}, i = 1, \dots, N \quad (7)$$

Obični se označavaju sa e_i zato što su procijenjene iz očekivanih vrijednosti $E[Y_i] = \mu_i$. Kako je $Var(Y_i) = E[Y_i]$ za Poissonovu distribuciju, standardna greška od Y_i se procjenjuje kao $\sqrt{e_i}$, pa slijedi da Pearsonove rezidualne računamo po formuli

$$r_i = \frac{o_i - e_i}{\sqrt{e_i}} \quad (8)$$

Pri čemu o_i označava promatranu vrijednost od Y_i .

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

Možemo koristiti Z - statistika koja je opisana kao

$$\frac{\hat{\beta}_k}{s.g.(\hat{\beta}_k)} \quad (9)$$

(s.g.-standardna greška)

koja bi uz nul hipotezu $\beta_k = 0$ trebala imati aproksimativno normalnu razdiobu, pa se nul-hipotezu može odbaciti kada je taj izraz po aproksimativnoj vrijednosti veći od $1.95 \approx 2$

3.2.3 Test prilagodbe podacima

Kao testna statistika koristit će se devijanca. Devijanca je mjera koja pokazuje koliko se dobro model prilagođava podacima. Formula za devijancu može se izvesti iz omjera vjerodostojnosti između odabranog modela i saturiranog modela. Saturirani model je model za koji predviđene vrijednosti iz modela točno odgovaraju promatranim ishodima. Prvo se nađe maksimum log-vjerodostojne funkcije u restringiranom modelu, recimo $l(b; y)$ i maksimum log-vjerodostojne funkcije u zasićenom (saturiranom) modelu $l(b_{max}; y)$.

$$l(b_{max}; y) = \sum y_i \log(y_i) - \sum y_i - \sum \log y_i! \quad (10)$$

Ako model od interesa sadrži p varijabli pri čemu je $p < N$. U tom slučaju funkcija maksimalne log-vjerodostojnosti dana je sa

$$l(b; y) = \sum y_i \log \hat{y}_i - \hat{y}_i - \sum \log y_i! \quad (11)$$

Devijanca se definira kao mjera odstupanja opažene od očekivane vrijednosti dane modelom. Devijanca za Poissonov model može se zapisati kao

$$2[l(b_{max}; y) - l(b; y)] \quad (12)$$

Rezidualna devijanca sastavni je dio od D .

$$d_i = \text{sign}(o_i - e_i) \sqrt{2o_i \log(o_i/e_i) - (o_i - e_i)}, i = 1, \dots, N \quad (13)$$

Pa se D može zapisati kao $D = \sum d_i^2$.

Ako je model dobar asimptotski će vrijediti

$$D \sim \chi_{N-p}^2 \quad (14)$$

Također postoji i AIC vrijednost tj. Akaike informacijski kriterij. AIC je relativna mjera koja se temelji na ocjeni kompleksnosti modela. Najbolji model je onaj s najnižom vrijednošću AIC. Uz pretpostavku da je p broj parametar u modelu, a $l(b_{max}; y)$ maksimalna

vrijednost funkcije vjerodostojnosti, AIC se računa na sljedeći način

$$AIC = 2p - 2\ln(l(b_{max}; y)) \quad (15)$$

3.2.4 Test disperzije

Kao što je rečeno uvjetno očekivanje zavisne varijable jednako je uvjetnoj varijanci zavisne varijable kod Poissonove distribucije. Poissonova se regresija ponekad ne pokazuje kao najbolji izbor jer je često varijanca veća od očekivanja što dovodi do prekomjerne disperzije (ekvidisperzije) podataka. U takvim slučajevima sami procijenjeni koeficijenti su i dalje konzistentni, ali su standardne pogreške različite, a samim time i p-vrijednosti i intervali pouzdanosti krivi.

4 Empirijska analiza

U ovom dijelu rada proći će se deskriptivna statistika svake varijabla. Zatim će se provesti Poissonova regresija i naposljetku prokomentirati dobiveni rezultate i njihova statistička značajnost.

4.1 Deskriptivna statistika

Deskriptivna statistika bavi se egzaktnim proučavanjem statističkih podataka, odnosno sređivanjem, prikazivanjem i interpretiranjem statističkih podataka, definiranjem glavnih parametara, utvrđivanjem njihovih teorijskih svojstava i njihovog praktičnog značenja.

4.1.1 Deskriptivna statistika županija

Zavisna varjabla OLBI mjeri se brojem objavljenim dokumenata i koja može poprimiti vrijednosti 0 do 5.

U tablici 3 prikazane je deskriptivna statistika zavisne varijable OLBI na razini županija.

Srednja vrijednost	Standardna devijacija	Minimalna vrijednost	Maksimalna vrijednost
4.6	0.754	0	5

Izvor: izrada autorice

Tablica 3: Deskriptivna statistika zavisne varijable OLBI

Promatranjem broja objavljenih proračunskih dokumenata zaključuje se da je najviše njih objavilo 5 dokumenta, točnije 70%, zatim 25% je objavilo 4 dokumenta, 5% objavilo je 2 dokumenta i naposljetku 0% objavilo je 3 dokumenta, 1 dokument ili niti jedan dokument. S obzirom na prošlu godinu gdje je prosječna proračunska transparentnost županija iznosila 4.3 vidi se mali porast na 4.6.

U tablici 4 prikazana je deskriptivna statistika nezavisnih varijabli.

	Srednja vrijednost	Standardna devijacija	Minimalna vrijednost	Maksimalna vrijednost
Prvi krug	0.45	0.510	0	1
Ljevica	0.3	0.470	0	1
Koalicija	1	0	0	1
VOpol	0.9	0.308	0	1
Gpol	52	8.137	33	67
Def Suf	0.043	0.042	-0.051	0.116

Izvor: izrada autorice

Tablica 4: Deskriptivna statistika nezavisnih varijabli

U tablici 5 prikazane su korelacije varijable OLBI i nezavisnih varijabli i korelacije među nezavisnim varijablama.

	OLBI	Prvi krug	Ljevica	Koalicija	VOpol	Gpol	Def Suf
OLBI	1	-0.055	0.207	0	0.045	-0.025	-0.235
Prvi krug	-0.05	1	0.0657	0	-0.033	0.139	0.323
Ljevica	0.207	0.065	1	0	0.218	-0.110	-0.102
Koalicija	0	0	0	0	0	0	0
VOpol	0.045	-0.033	0.218	0	1	-0.084	-0.160
Gpol	-0.025	0.139	-0.110	0	-0.084	1	-0.163
Def Suf	-0.235	0.323	-0.102	0	-0.160	-0.163	1

Izvor: izrada autorice

Tablica 5: Tablica korelacija

Iz tablice 5 međusobnih korelacija vidi se da sa zavisnom varijablom OLBI najviše koreliraju nezavisne varijable ljevica na vlasti i deficit/suficit. Nezavisna varijabla ljevica na vlasti pozitivno korelira s OLBI varijablom, dok kod nezavisne varijable deficit/suficit postoji negativna korelacija s varijablom OLBI. Velika koreliranost među varijablama može narušiti točnost procijenjenog modela, pa je bolje da ne idu u isti model.

Ako se promatra koreliranost nezavisnih varijabli najviše koreliraju varijable deficit/suficit i političari izabrani u prvom krugu i to pozitivno, te varijable ljevica na vlasti i visoko-obrazovani političari također je primjetna pozitivna korelacija.

4.1.2 Deskriptivna statistika gradova

U tablici 6 prikazana je deskriptivna statistika zavisne varijable OLBI na razini gradova.

Srednja vrijednost	Standardna devijacija	Minimalna vrijednost	Maksimalna vrijednost
3.664	1.299	0	5

Izvor: izrada autorice

Tablica 6: Deskriptivna statistika zavisne varijable OLBI

Promatranjem broja objavljenih proračunskih dokumenata vidi se da je najviše njih objavilo 4 dokumenta, točnije 35.16%, zatim 29.69% je objavilo 5 dokumenata, 18.75% objavilo je 3 dokumenta, 7.81% objavilo je 2 dokumenata, 5.46% ih je objavilo 1 dokument i naposljetku 3.13% gradova nije objavilo niti jedan dokument. S obzirom na prošlu godinu gdje je prosječna proračunska transparentnost gradova iznosila 3.05 primjetan je mali porast na 3.66, ali on još uvijek nije zadovoljavajući.

Tablica 7 prikazuje deskriptivnu statistiku nezavisnih varijabli.

	Srednja vrijednost	Standardna devijacija	Minimalna vrijednost	Maksimalna vrijednost
Prvi krug	0.320	0.468	0	1
Ljevica	0.305	0.462	0	1
Koalicija	0.695	0.462	0	1
VOpol	0.679	0.468	0	1
Gpol	52.203	8.062	32	69
Def Suf	0.009	0.115	-0.428	0.448

Izvor: izrada autorice

Tablica 7: Deskriptivna statistika nezavisnih varijabli

Tablica 8 prikazuje korelacije varijable OLBI i nezavisnih varijabli i korelacije među nezavisnim varijablama.

	OLBI	Prvi krug	Ljevica	Koalicija	VOpol	Gpol	Def Suf
OLBI	1	-0.18	0.04	0.05	-0.06	0.15	-0.08
Prvi krug	-0.18	1	-0.09	0.09	-0.10	-0.07	0.00
Ljevica	0.04	-0.09	1	0.33	0.02	-0.00	-0.00
Koalicija	0.05	0.09	0.33	1	-0.09	-0.11	0.03
VOpol	-0.06	0.10	0.02	-0.09	1	-0.15	-0.00
Gpol	0.15	-0.07	-0.00	-0.11	-0.15	1	0.03
Def Suf	-0.08	-0.00	0.00	0.03	-0.00	0.03	1

Izvor: izrada autorice

Tablica 8: Tablica korelacija

Iz tablice 8 međusobnih korelacija vidi se da sa zavisnom varijablom OLBI najviše koreliraju nezavisne varijable političari izabrani u prvom krugu izbora, te godine političara. Može se primijetiti da obje pozitivno koreliraju s OLBI varijablom.

Ako se promatra koreliranost između nezavisnih varijabli najviše koreliraju varijable koalicija na vlasti i ljevica na vlasti, također je prisutna pozitivna korelacija, te varijable visoko obrazovani političari i dob političara i primjećuje se negativna korelacija.

4.1.3 Deskriptivna statistika općina

Tablica 9 prikazuje deskriptivnu statistiku zavisne varijable OLBI.

Srednja vrijednost	Standardna devijacija	Minimalna vrijednost	Maksimalna vrijednost
2.836	1.505	0	5

Izvor: izrada autorice

Tablica 9: Deskriptivna statistika zavisne varijable OLBI na razini općina

Promatranjem broja objavljenih proračunskih dokumenata vidi se da je najviše njih objavilo 3 dokumenta, točnije 27.1%, zatim 19.39% je objavilo 4 dokumenta, 16.82% objavilo je 2 dokumenta, 15.89% objavilo je 5 dokumenata, 11.68% ih je objavilo 1 dokument i naposljetku 9.12% općina nije objavilo niti jedan dokument. S obzirom na prošlu godinu gdje je prosječna proračunska transparentnost općina iznosila 2.04 vidi se mali porast na 2.836, ali on još uvijek nije zadovoljavajući.

Tablica 10 prikazuje deskriptivnu statistiku nezavisnih varijabli.

	Srednja vrijednost	Standardna devijacija	Minimalna vrijednost	Maksimalna vrijednost
Prvi krug	0.617	0.487	0	1
Ljevica	0.196	0.397	0	1
Koalicija	0.390	0.489	0	1
VOpol	0.367	0.483	0	1
Gpol	49.998	9.934	25	77
Def Suf	0.011	0.208	-1.052	0.695

Izvor: izrada autorice

Tablica 10: Deskriptivna statistika nezavisnih varijabli

Tablica 11 prikazuje korelacije varijable OLBI i nezavisnih varijabli i korelacije među nezavisnim varijablama.

	OLBI	Prvi krug	Ljevica	Koalicija	VOpol	Gpol	Def Suf
OLBI	1	0.074	0.128	0.087	0.034	0.050	0.055
Prvi krug	0.074	1	-0.082	0.029	0.032	-0.07	-0.020
Ljevica	0.128	-0.082	1	0.340	0.014	-0.016	0.002
Koalicija	0.087	0.029	0.340	1	-0.092	0.007	-0.023
VOpol	0.034	0.032	0.014	-0.092	1	-0.114	0.062
Gpol	0.050	-0.07	-0.016	0.007	-0.114	1	0.003
Def Suf	0.055	-0.020	0.002	-0.023	0.062	0.003	1

Izvor: izrada autorice

Tablica 11: Tablica korelacija

Iz tablice međusobnih korelacija vidi se da sa zavisnom varijablom OLBI najviše korelira nezavisna varijabla ljevica na vlasti. Primjećuje se pozitivna korelacija s OLBI varijablom.

Ako se promatra koreliranost između nezavisnih varijabli najviše koreliraju varijable koalicija na vlasti i ljevica na vlasti, također se može primijetiti pozitivna korelacija, te varijable visoko obrazovani političari i dob političara i to negativni.

4.2 Poissonova regresija

U ovom dijelu rada provest će se Poissonova regresija na način opisan u poglavlju metodologija.

4.2.1 Poissonova regresija županija

Prvo se promatra MODEL 1 koji sadrži sve varijable, odnosno promatra se utjecaj svih izabranih nezavisnih varijabli na zavisnu varijablu OLBI.

$$\ln\left(\frac{\mu}{1-\mu}\right) = \exp\{\theta_0 + \theta_1 Prvikrug + \theta_2 Ljevica + \theta_3 VOpol + \theta_4 Gpol + \theta_5 DefSuf\} \quad (16)$$

	Procijenjeni koeficijent θ_i	Standardna greška	Z vrijednost	p vrijednost
Slobodni član	1.610	0.857	1.878	0.060
Prvi krug	0.004	0.229	0.018	0.985
Ljevica	0.063	0.234	0.269	0.787
VOpol	-0.018	0.364	-0.051	0.959
Gpol	-0.000	0.0139	-0.070	0.943
Def Suf	-0.895	2.786	-0.321	0.748

Izvor: izrada autorice

Tablica 12: Rezultati regresije dobiveni testiranjem MODELA 1

Analizirat će se dobiveni procijenjeni parametri θ_i . Promatra se nezavisna varijabla političar izabran u prvom krugu. Vidi se da je procijenjeni parametar $\theta_1 = 0.004$, njegova eksponencijalna vrijednost je 1.004. Zaključak je da za svako povećanje varijable političar izabran u prvome krugu za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti $(\mu/1-\mu)$ porasta transparentnosti bit će 0.4%. Vrijednost p se koristi za određivanje značajnosti svakog pojedinog procijenjenog regresijskog koeficijenta u modelu, odnosno testira se nulta hipoteza da je pojedini parametar jednak nuli. Ukoliko je p-vrijednost manja od 0.05 odbacuje se nul hipoteza, što znači da parametar nije jednak nuli, odnosno da je varijabla značajna. U našem slučaju p vrijednost

je izrazito velika pa se može zaključiti da varijabla nije statistički značajna.

Sljedeća varijabla koja se promatra je ljevica na vlasti. Analognim računanjem dobiva se da povećanje varijable ljevica na vlasti za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 6.5%. Ali p-vrijednost je opet velika pa se opet može zaključiti da varijabla nije statistički značajna.

Procijenjeni parametar nezavisne varijable visoko obrazovani političari daje informaciju da za svako povećanje varijable visoko obrazovani političari za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) smanjenje transparentnosti bit će 1.7%. p-vrijednost je velika pa je zaključak da varijabla nije statistički značajna.

Procijenjeni parametar nezavisne varijable dob političara daje informaciju da dob političara uopće ne utječe na povećanje/smanjenje OLBI varijable, a to potvrđuje i velika p-vrijednost.

Naposljetku procijenjeni parametar nezavisne varijable deficit/suficit daje informaciju da za svako povećanje varijable deficit/suficit za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) smanjenje transparentnosti bit će 59.6%. p-vrijednost je velika pa je zaključak da varijabla nije statistički značajna.

		Stupnjevi slobode
Null devijanca	2.751	19
Rezidualna devijanca	2.536	14

Izvor: izrada autorice

Tablica 13: Rezultati regresije dobiveni testiranjem MODELA 1

Nakon analize parametara koristi se mjera za ocjenu modela kako bi se utvrdila kvaliteta modela te kako bi se iz skupa testiranih modela mogli odabrati oni najprihvatljiviji. Testna statistika je provjera dolazi li devijanca iz χ^2 distribucije ² (null devijanca-rezidualna devijanca, df null devijance - df rezidualne devijance) dobivena p-vrijednost je 0.998, pa zaključujemo da je model dobro prilagođen podacima. AIC vrijednost modela je 82.207, ali ona će biti korisna pri usporedbi dvaju ili više modela. Model s najnižom AIC vrijednosti je najbolje prilagođen podacima.

²u R-u 1-pchisq

Kreira se MODEL 2 koji će se testirati. Naime prema matrici korelacija moglo se vidjeti da sa zavisnom varijablom OLBI najviše koreliraju varijable ljevica na vlasti i deficit/sufucit, pa će se u drugom modelu izbaciti te dvije varijable.

$$\ln\left(\frac{\mu}{1-\mu}\right) = \exp\{\theta_0 + \theta_1 Prvikrug + \theta_3 VOpol + \theta_4 Gpol\} \quad (17)$$

	Procijenjeni koeficijent θ_i	Standardna greška	Z vrijednost	p vrijednost
Slobodni član	1.529	0.786	1.944	0.0519
Prvi krug	-0.016	0.212	-0.078	0.938
VOpol	0.023	0.352	0.065	0.948
Gpol	-0.000	0.013	-0.023	0.981

Izvor: izrada autorice

Tablica 14: Rezultati regresije dobiveni testiranjem MODELA 2

Kao i u prethodnom modelu promatraju se procijenjeni koeficijenti nezavisnih varijabli i njihove p vrijednosti.

Svako povećanje varijable političar izabran u prvome krugu za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) smanjenja transparentnosti bit će 1.5% što je više nego u prvom modelu gdje je utjecaj bio 0.4%, ali u ovom modelu negativno utječe na varijablu OLBI, dok je u prvom pozitivno utjecala. Također, vidi se da se p-vrijednost smanjila ali i dalje nije statistički značajan utjecaj.

Svako povećanje varijable visoko obrazovani političari za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 2.3% što je više nego u prvom modelu gdje je utjecaj bio 1.7%. Također vidi se da se p-vrijednost smanjila, ali i dalje je zaključak isti odnosno naša varijabla nije statistički značajna.

Svako povećanje varijable dob političara za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene ne utječe na zavisnu varijablu OLBI što potvrđuje i velika p-vrijednost.

		Stupnjevi slobode
Null devijanca	2.751	19
Rezidualna devijanca	2.739	16

Izvor: izrada autorice

Tablica 15: Rezultati regresije dobiveni testiranjem MODELA 2

Koriste se mjere za ocjenu modela kako bi se utvrdila kvaliteta modela te kako bi se iz skupa testiranih modela mogli odabrati oni najprihvatljiviji. Testna statistika je provjera dolazi li devijanca iz χ^2 distribucije (null devijanca-rezidualna devijanca, df null devijance - df rezidualne devijance) dobivena p-vrijednost je 0.999, pa je zaključak da je model dobro prilagođen podacima.

Zaključak je da se smanjenjem varijabli u modelu nije dobio značajno bolji rezultat.

AIC vrijednost modela je 78.41. Najbolji model je onaj s najnižom AIC vrijednosti, ali budući da je AIC manji što je broj parametara manji ne može se zaključiti da je MODEL2 značajno bolji jer je razlika u AIC vrijednostima mala.

Proveden je i test disperzije podataka kojim se dobiva da je u odabranim modelima došlo do ekvidisperzije podataka (prekomjerne disperzije) odnosno problem prenaučivosti: izgrađeni model je previše prilagođen skupu za učenje i dalje uči samo šum, koji nije dio stvarne domene koja se analizira.

4.2.2 Poissonova regresija gradova

Analogno se prvo promatra MODEL 1 koji sadrži sve varijable, odnosno promatra se utjecaj svih izabranih nezavisnih varijabli na zavisnu varijablu OLBI.

$$\ln\left(\frac{\mu}{1-\mu}\right) = \exp\{\theta_0 + \theta_1 Prvikrug + \theta_2 Ljevica + \theta_3 Koalicija + \theta_4 VOpol + \theta_5 Gpol + \theta_6 DefSuf\} \quad (18)$$

	Procijenjeni koeficijent θ_i	Standardna greška	Z vrijednost	p vrijednost
Slobodni član	1.015	0.351	2.890	0.0039
Prvi krug	-0.145	0.104	-1.395	0.163
Ljevica	-0.000	0.106	-0.001	0.999
Koalicija	0.060	0.109	0.552	0.581
VOpol	-0.039	0.101	-0.390	0.696
Gpol	0.006	0.006	1.017	0.309
Def Suf	-0.044	0.397	-0.111	0.911

Izvor: izrada autorice

Tablica 16: Rezultati regresije dobiveni testiranjem MODELA 1

Analiziraju se dobiveni procijenjeni parametri θ_i . Promatranjem nezavisne varijable političar izabran u prvom krugu vidi se da je procijenjeni parametar $\theta_1 = -0.145$, njegova eksponencijalna vrijednost je 0.87, ali budući da je predznak negativan mora se izračunati $1-0.87=0.13$. Zaključak je da za svako povećanje varijable političar izabran u prvome krugu za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti $(\mu/1-\mu)$ porasta transparentnosti bit će 13%. Vrijednost p se koristi za određivanje značajnosti svakog pojedinog procijenjenog regresijskog koeficijenta u modelu, odnosno testira se nulta hipoteza da je pojedini parametar jednak nuli. Ukoliko je p-vrijednost manja od 0.05 odbacuje se nulta hipoteza, što znači da parametar nije jednak nuli, odnosno da je varijabla značajna. U našem slučaju p vrijednost je izrazito velika pa se može zaključiti da varijabla nije statistički značajna.

Sljedeća varijabla koja se promatra je ljevica na vlasti. Analognim računanjem dobiva se da ljevica uopće ne utječe na smanjenje/povećanje zavisne varijable OLBI, a to potvrđuje p-vrijednost, koja je približno jednaka 1.

Promatranjem procijenjenog parametra nezavisne varijable koalicija na vlasti zaključak je da za svako povećanje varijable koalicija na vlasti za 1 jedinicu, uz uvjet da su ostale

varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 6.1%. Ali p-vrijednost je opet velika pa je zaključak da varijabla nije statistički značajna.

Procijenjeni parametar nezavisne varijable visoko obrazovani političari daje informaciju da za svako povećanje varijable visoko obrazovani političari za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) smanjenja transparentnosti bit će 3.8%. P-vrijednost je velika pa je zaključak da varijabla nije statistički značajna.

Procijenjeni parametar nezavisne varijable dob političara daje informaciju da za svako povećanje varijable dob političara za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 0.6%. P-vrijednost je velika pa je zaključak da varijabla nije statistički značajna.

Naposljetku procijenjeni parametar nezavisne varijable defici/suficit daje informaciju da za svako povećanje varijable defici/suficit za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) smanjenje transparentnosti bit će 4.3%. P-vrijednost je velika pa je zaključak da varijabla nije statistički značajna.

		Stupnjevi slobode
Null devijanca	78.517	127
Rezidualna devijanca	74.851	121

Izvor: izrada autorice

Tablica 17: Rezultati regresije dobiveni testiranjem MODELA 1

Nakon analize parametara koriste se mjere za ocjenu modela kako bi se utvrdila kvaliteta modela te kako bi se iz skupa testiranih modela mogli odabrati oni najprihvatljiviji. Testna statistika je provjera dolazi li devijanca iz χ^2 distribucije (null devijanca-rezidualna devijanca, df null devijance - df rezidualne devijance) dobivena p-vrijednost je 0.723, pa je zaključak da je model dobro prilagođen podacima. AIC vrijednost modela je 480.01, ali ona će biti korisna pri usporedni dva ili više modela. Model s najnižom AIC vrijednosti je najbolje prilagođen podacima.

Kreiraju se dodatni modeli za testiranje. Naime prema matrici korelacija vidi se da sa zavisnom varijablom OLBI najviše koreliraju varijable političari izabrani u prvom krugu i dob političara. Kod varijable političari izabrani u prvom krugu primjećuje se negativna korelacija s OLBI varijablom, dok se kod varijable dob političara primjećuje pozitivna korelacija s OLBI varijablom. Međusobno najviše koreliraju varijable ljevica na vlasti i

koalicija na vlasti. Stoga se testiraju još tri modela. U MODELU 2 izbacit će se varijable političari izabrani u prvom krugu i visokoobrazovani političari. U trećem modelu će se iz drugog modela izbaciti varijablu ljevica na vlasti, a u četvrtom će se iz drugog modela izbaciti koaliciju na vlasti.

$$\ln\left(\frac{\mu}{1-\mu}\right) = \exp\{\theta_0 + \theta_2 Ljevica + \theta_3 Koalicija + \theta_4 VOpol + \theta_6 DefSuf\} \quad (19)$$

	Procijenjeni koeficijent θ_i	Standardna greška	Z vrijednost	p vrijednost
Slobodni član	1.302	0.112	11.656	<2e-16
Ljevica	0.023	0.106	0.215	0.830
Koalicija	0.028	0.108	0.261	0.794
VOpol	-0.044	0.099	-0.449	0.654
Def Suf	-0.031	0.402	-0.077	0.939

Izvor: izrada autorice

Tablica 18: Rezultati regresije dobiveni testiranjem MODELA 2

Kao i u prethodnom modelu promatraju se procijenjeni koeficijenti nezavisnih varijabli i njihova pripadna p-vrijednost.

Svako povećanje varijable ljevica na vlasti za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 2.3% što je više nego u prvom modelu gdje uopće nije utjecala na OLBI varijablu. Također vidi se da se p-vrijednost smanjila, ali ne dovoljno pa je zaključak isti, odnosno varijabla nije statistički značajna.

Svako povećanje varijable koalicija na vlasti za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 2.8% što je manje nego u prvom modelu gdje je utjecaj bio 6.1%. Također p-vrijednost se povećala, pa je zaključak isti odnosno varijabla nije statistički značajna.

Svako povećanje varijable visokoobrazovani političari za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) smanjenja transparentnosti bit će 4.3% što je manje nego u prvom modelu gdje je bilo 3.8%. P-vrijednost se smanjila, ali i dalje je prevelika pa je zaključak isti odnosno varijabla nije statistički značajna.

Svako povećanje varijable deficit ili suficit, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 3.1% što je

manje nego u prvom modelu i u prvom modelu je bio negativan utjecaj na OLBI varijablu dok je u ovom modelu pozitivan. P-vrijednost se povećala, pa je zaključak isti odnosno naša varijabla nije statistički značajna.

		Stupnjevi slobode
Null devijanca	78.517	127
Rezidualna devijanca	78.120	123

Izvor: izrada sutorice

Tablica 19: Rezultati regrsije dobiveni testiranjem MODELA 2

Koriste se mjere za ocjenu modela kako bi se utvrdila njegova kvaliteta te kako bi se iz skupa testiranih modela mogli odabrati oni najprihvatljiviji. Testna statistika je provjera dolazi li devijanca iz χ^2 distribucije (null devijanca-rezidualna devijanca, df null devijance - df rezidualne devijance) dobivena p-vrijednost je 0.983, pa je zaključak da je model dobro prilagođen podacima.

Zatim se promatra MODEL 3:

$$\ln\left(\frac{\mu}{1-\mu}\right) = \exp\{\theta_0 + \theta_3 Koalicija + \theta_4 VOpol + \theta_6 DefSuf\} \quad (20)$$

	Procijenjeni koeficijent θ_i	Standardna greška	Z vrijednost	p vrijednost
Slobodni član	1.303	0.112	11.676	<2e-16
Koalicija	0.036	0.102	0.352	0.725
VOpol	-0.043	0.099	-0.438	0.661
Def Suf	-0.031	0.402	-0.078	0.939

Izvor: izrada autorice

Tablica 20: Rezultati regresije dobiveni testiranjem MODELA 3

Svako povećanje varijable koalicija na vlasti za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti $(\mu/1-\mu)$ porasta transparentnosti bit će 3.6% što je manje nego u prvom modelu gdje je utjecaj bio 6.1%, a više nego u drugom modelu gdje je utjecaj bio 2.8%. Vidimo da je p-vrijednost i dalje velika pa je zaključak isti, odnosno varijabla nije statistički značajna.

Svako povećanje varijable visokoobrazovani političari za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) smanjenje transparentnosti bit će 4.2% što je gotovo isto kao u drugom modelu. P-vrijednost se povećala pa je zaključak isti, odnosno varijabla nije statistički značajna.

Svako povećanje varijable deficit ili suficit, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 3.1% što je jednako kao u drugom modelu samo je ovdje utjecaj negativan na OLBI varijablu dok je u drugom modelu bio pozitivan. P-vrijednost je ista pa je zaključak isti, odnosno varijabla nije statistički značajna.

		Stupnjevi slobode
Null devijanca	78.517	127
Rezidualna devijanca	78.166	124

Izvor: izrada autorice

Tablica 21: Rezultati regresije dobiveni testiranjem MODELA 3

Koristi se mjera za ocjenu modela kako bi se utvrdila njegova kvaliteta te kako bi se iz skupa testiranih modela mogli odabrati oni najprihvatljiviji. Testna statistika je provjera dolazi li devijanca iz χ^2 distribucije (null devijanca-rezidualna devijanca, df null devijance - df rezidualne devijance) dobivena p-vrijednost je 0.950, pa se može zaključiti da je model dobro prilagođen podacima.

AIC vrijednost modela je 477.33. Zna se da je najbolji model onaj s najnižom AIC vrijednosti, ali budući da je AIC manji što je broj parametara manji ne može se zaključiti da je MODEL 3 značajno bolji jer je razlika u AIC vrijednostima mala.

Preostaje posljednji MODEL 4:

$$\ln\left(\frac{\mu}{1-\mu}\right) = \exp\{\theta_0 + \theta_2 Ljevica + \theta_4 VOpol + \theta_6 DefSuf\} \quad (21)$$

	Procijenjeni koeficijent θ_i	Standardna greška	Z vrijednost	p vrijednost
Slobodni član	1.321	0.086	15.397	<2e-16
Ljevica	0.032	0.099	0.320	0.749
VOpol	-0.047	0.098	-0.478	0.633
Def Suf	-0.028	0.402	-0.071	0.944

Izvor: izrada autorice

Tablica 22: Rezultati regresije dobiveni testiranjem MODELA 4

Kao i u prethodnom modelu promatraju se procijenjeni koeficijenti nezavisnih varijabli i njihova pripadna p-vrijednost.

Svako povećanje varijable ljevica za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 3.2% što je više nego u ostalim modelima. Vidi se da je p-vrijednost i dalje velika pa je zaključak isti odnosno varijabla nije statistički značajna.

Svako povećanje varijable visokoobrazovani političari za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) smanjenja transparentnosti bit će 4.6% što je više nego u prethodnim modelima. P-vrijednost je i dalje velika pa je zaključak isti odnosno varijabla nije statistički značajna.

Svako povećanje varijable deficit ili suficit, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) pad transparentnosti bit će 2.7%. P-vrijednost je ista pa je zaključak isti odnosno varijabla nije statistički značajna.

		Stupnjevi slobode
Null devijanca	78.517	127
Rezidualna devijanca	78.189	124

Izvor: izrada autorice

Tablica 23: Rezultati regresije dobiveni testiranjem MODELA 4

Koriste se mjere za ocjenu. Testna statistika je provjera dolazi li devijanca iz χ^2 distribucije (null devijanca-rezidualna devijanca, df null devijance - df rezidualne devijance) dobivena p-vrijednost je 0.999, pa je zaključak da je model dobro prilagođen podacima.

AIC vrijednost modela je 477.35. Zna se da je najbolji model onaj s najnižom AIC vrijednosti, ali budući da je AIC manji što je broj parametara manji ne može se zaključiti da je MODEL 4 značajno bolji jer je razlika u AIC vrijednostima mala.

Proveden je test disperzije podataka koji ukazuje da je u modelima došlo do ekvidisperzije podataka (porekomjerne disperzije) odnosno problema prenaučenosti: izgrađeni model je previše prilagođen skupu za učenje i dalje uči samo šum, koji nije dio stvarne domene koja se analizira.

4.2.3 Poissonova regresija općina

Analogno se promatra MODEL 1 koji sadrži sve varijable, odnosno promatra se utjecaj svih izabranih nezavisnih varijabli na zavisnu varijablu OLBI.

$$\ln\left(\frac{\mu}{1-\mu}\right) = \exp\{\theta_0 + \theta_1 Prvikrug + \theta_2 Ljevica + \theta_3 Koalicija + \theta_4 VOpol + \theta_5 Gpol + \theta_6 DefSuf\} \quad (22)$$

	Procijenjeni koeficijent θ_i	Standardna greška	Z vrijednost	p vrijednost
Slobodni član	0.801	0.157	5.110	$3.23 \cdot 10^{-7}$
Prvi krug	0.083	0.060	1.370	0.171
Ljevica	0.149	0.0741	2.009	0.044
Koalicija	0.053	0.063	0.845	0.398
VOpol	0.039	0.060	0.663	0.507
Gpol	0.002	0.003	0.812	0.416
Def Suf	0.141	0.139	1.011	0.312

Izvor: izrada autorice

Tablica 24: Rezultati regresije dobiveni testiranjem MODELA 1

Analizira se dobiveni procijenjeni parametar θ_i . Promatranjem nezavisne varijable političar izabran u prvom krugu. Vidi se da je procijenjeni parametar $\theta_1 = 0.083$, njegova eksponencijalna vrijednost je 1.087. Zaključak je da za svako povećanje varijable političar izabran u prvome krugu za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti $(\mu/1-\mu)$ porasta transparentnosti bit će 8.7%. Vrijednost p se koristi za određivanje značajnosti svakog pojedinog procijenjenog regresijskog koeficijenta u modelu, odnosno testira se nulta hipoteza da je pojedini parametar jednak nuli. Ukoliko je p-vrijednost manja od 0.05 odbacuje se nult hipotez, što znači da parametar nije jednak nuli, odnosno da je varijabla značajna. U našem slučaju p-vrijednost je izrazito velika pa možemo zaključiti da varijabla nije statistički značajna.

Sljedeća varijabla je ljevica na vlasti. Analognim računanjem dobiva se da za svako povećanje varijable ljevica na vlasti u prvome krugu za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti $(\mu/1-\mu)$ porasta transparentnosti bit će 16.1%. Ovdje je p-vrijednost manja od 0.05 pa je zaključak da je varijabla statistički značajna.

Promatranjem procijenjenog parametra nezavisne varijable koalicija na vlasti zaključak je da za svako povećanje varijable koalicija na vlasti za 1 jedinicu, uz uvjet da su ostale

varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 5.4%. Ali p-vrijednost je velika, pa je zaključak da varijabla nije statistički značajna.

Procijenjeni parametar nezavisne varijable visokoobrazovani političari daje informaciju da za svako povećanje varijable visoko obrazovani političari za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 3.9%. P-vrijednost je velika, pa je zaključak da varijabla nije statistički značajna.

Procijenjeni parametar nezavisne varijable dob političara daje informaciju da za svako povećanje varijable dob političara za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 0.2%. P-vrijednost je velika, pa je zaključak da varijabla nije statistički značajna.

Naposljetku procijenjeni parametar nezavisne varijable deficit/suficit daje informaciju da za svako povećanje varijable deficit/suficit za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 15.1%. P-vrijednost je velika pa je zaključak da varijabla nije statistički značajna.

Može se primjetiti da ovdje sve nezavisne varijable imaju pozitivan učinak na transparentnost, odnosno svi procijenjeni koeficijenti su pozitivnog predznaka.

		Stupnjevi slobode
Null devijanca	447.86	427
Rezidualna devijanca	437.27	421

Izvor: izrada autorice

Tablica 25: Rezultati regresije dobiveni testiranjem MODELA 1

Nakon analize parametara koristi se mjera za ocjenu modela kako bi se utvrdila njegova kvaliteta te kako bi se iz skupa testiranih modela mogli odabrati oni najprihvatljiviji. Testna statistika je provjera dolazi li devijanca iz χ^2 distribucije (null devijanca-rezidualna devijanca, df null devijance - df rezidualne devijance) dobivena p-vrijednost je 0.102, pa je zaključak da je model dobro prilagođen podacima. AIC vrijednost modela je 1594.3, ali ona će biti korisna pri usporedni dva ili više modela. Zna se da je model s najnižom AIC vrijednosti najbolje prilagođen podacima.

Kreirat će se još dva modela koja će se testirati. Naime prema matrici korelacija vidi se da najviše koreliraju nezavisne varijable koalicija na vlasti i ljevica na vlasti, pa će se u

MODELU 2 izbaciti varijabla koalicija na vlasti, a zatim u trećem modelu izbaciti varijablu ljevica na vlasti jer ona najviše korelira s OLBI varijablom, a to bi moglo narušiti točnost procijenjenog parametra.

$$\ln\left(\frac{\mu}{1-\mu}\right) = \exp\{\theta_0 + \theta_1 Prvikrug + \theta_2 Ljevica + \theta_4 VOpol + \theta_5 Gpol + \theta_6 DefSuf\} \quad (23)$$

	Procijenjeni koeficijent θ_i	Standardna greška	Z vrijednost	p vrijednost
Slobodni član	0.819	0.155	5.283	$1.27 * 10^{-7}$
Prvi krug	0.087	0.061	1.429	0.153
Ljevica	0.171	0.0691	2.481	0.013
VOpol	0.034	0.059	0.571	0.568
Gpol	0.002	0.003	0.801	0.423
Def Suf	0.141	0.140	1.002	0.316

Izvor: izrada autorice

Tablica 26: Rezultati regresije dobiveni testiranjem MODELA 2

Kao i u prethodnom modelu promatraju se procijenjeni koeficijenti nezavisnih varijabli i njihova pripadna p-vrijednost.

Svako povećanje varijable političar izabran u prvome krugu za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti $(\mu/1-\mu)$ porasta transparentnosti bit će 9.1% što je više nego u prvom modelu gdje je utjecaj bio 8.7%. Također, p-vrijednost se smanjila, ali ne dovoljno pa je zaključak isti, odnosno varijabla nije statistički značajna.

Svako povećanje varijable ljevica na vlasti za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti $(\mu/1-\mu)$ porasta transparentnosti bit će 18.6% što je više nego u prvom modelu gdje je utjecaj bio 16.1%. Također vidi se da se p-vrijednost smanjila. Varijabla je statistički značajna.

Svako povećanje varijable visoko obrazovani političar za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti $(\mu/1-\mu)$ porasta transparentnosti bit će 3.5% što je manje nego u prvom modelu gdje je utjecaj bio 3.9%. Također vidi se da se p-vrijednost povećala, pa je zaključak isti odnosno varijabla nije statistički značajna.

Svako povećanje varijable dob političara za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 0.2% što je isto kao u prvom modelu. P-vrijednost se povećala pa je zaključak isti odnosno varijabla nije statistički značajna.

Svako povećanje varijable deficit/suficit, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 15.1% što je isto kao u prvom modelu. P-vrijednost se povećala, pa je zaključak isti odnosno varijabla nije statistički značajna.

		Stupnjevi slobode
Null devijanca	447.86	427
Rezidualna devijanca	437.99	422

Izvor: izrada autorice

Tablica 27: Rezultati regresije dobiveni testiranjem MODELA 2

Koriste se mjere za ocjenu modela kako bi se utvrdila kvaliteta modela te kako bi se iz skupa testiranih modela mogli odabrati oni najprihvatljiviji. Testna statistika je provjera dolazi li devijanca iz χ^2 distribucije (null devijanca-rezidualna devijanca, df null devijance - df rezidualne devijance) dobivena p-vrijednost je 0.079, pa je zaključak da je model dobro prilagođen podacima.

AIC vrijednost modela je 1593. Najbolji model je onaj s najnižom AIC vrijednosti, ali budući da je AIC manji što je broj parametara manji ne može se zaključiti da je MODEL2 značajno bolji jer je razlika u AIC vrijednostima mala.

Idući testirani model je MODEL 3:

$$\ln\left(\frac{\mu}{1-\mu}\right) = \exp\{\theta_0 + \theta_1 Prvikrug + \theta_4 VOpol + \theta_5 Gpol + \theta_6 DefSuf\} \quad (24)$$

	Procijenjeni koeficijent θ_i	Standardna greška	Z vrijednost	p vrijednost
Slobodni član	0.862	0.155	5.575	$2.47 \cdot 10^{-8}$
Prvi krug	0.074	0.060	1.230	0.219
VOpol	0.037	0.059	0.622	0.534
Gpol	0.002	0.003	0.801	0.423
Def Suf	0.139	0.139	1.001	0.317

Izvor: izrada autorice

Tablica 28: Rezultati regresije dobiveni testiranjem MODELA 3

Kao i u prethodnom modelu promatraju se procijenjeni koeficijenti nezavisnih varijabli i njihova pripadna p-vrijednost.

Svako povećanje varijable političar izabran u prvome krugu za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 7.6% što je manje nego u prva dva modele. Također vidi se da se p-vrijednost povećala pa je zaključak isti, odnosno varijabla nije statistički značajna.

Svako povećanje varijable visokoobrazovani političar za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani pad omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 3.7% što je manje nego u prvom modelu gdje je utjecaj bio 3.9%, ali veće nego u drugom modelu gdje je bilo 3.5%. Također vidi se da je p-vrijednost velika, odnosno varijabla nije statistički značajna.

Svako povećanje varijable dob političara za 1 jedinicu, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 0.2% što je isto kao u prva dva modela. P-vrijednost se povećala pa je zaključak isti odnosno varijabla nije statistički značajna.

Svako povećanje varijable deficit/suficit, uz uvjet da su ostale varijable nepromijenjene, očekivani rast omjera vjerojatnosti ($\mu/1-\mu$) porasta transparentnosti bit će 14.91% što je manje nego u prva dva modele. P-vrijednost je velika odnosno varijabla nije statistički značajna.

		Stupnjevi slobode
Null devijanca	447.86	427
Rezidualna devijanca	443.95	423

Izvor: izrada autorice

Tablica 29: Rezultati regresije dobiveni testiranjem MODELA 3

Koriste se mjere za ocjenu modela kako bi se utvrdila kvaliteta modela te kako bi se iz skupa testiranih modela mogli odabrati oni najprihvatljiviji. Testna statistika je provjera dolazi li devijanca iz χ^2 distribucije (null devijanca-rezidualna devijanca, df null devijance - df rezidualne devijance) dobivena p-vrijednost je 0.4183, pa je zaključak da je model dobro prilagođen podacima.

AIC vrijednost modela je 1592. Najbolji model onaj s najnižom AIC vrijednosti, ali budući da je AIC manji što je broj parametara manji ne možemo se zaključiti da je MODEL 3 značajno bolji jer je razlika u AIC vrijednostima mala.

Provodi se još test disperzije podataka kojim se dobiva da je u testiranim modelima došlo do prekomjerne disperzije odnosno problem prenaučenosti: izgrađeni model je previše prilagođen skupu za učenje i dalje uči samo šum, koji nije dio stvarne domene koja se analizira,

5 Zaključak

Cilj ovog diplomskog rada bio je ispitati postoji li veza između proračunske transparentnosti i odabranih varijabli. Krenulo se s pretpostavkama da varijable političar izabran u prvom krugu i koalicija na vlasti negativno utječu na transparentnost, a varijable ljevica na vlasti, dob političara i deficit pozitivno utječu na transparentnost.

U tu svrhu za testiranje se koristila Poissonova regresija koja se, po uzoru na ranija istraživanja, pokazala najboljom. Nakon provedbe Poissonove regresije može se zaključiti da ljevica na vlasti pozitivno utječe na transparentnost općina, odnosno može se potvrditi jedna od početnih pretpostavki, dok se ostale varijable nisu pokazale statistički značajnim.

Rezultate je potrebno interpretirati s oprezom, jer se provedbom testa disperzije pokazalo da Poissonova regresija nije najbolji odabir zbog prekomjerne disperzije (ekvidisperzije) podataka. Izgrađeni model je previše prilagođen skupu za učenje i dalje uči samo šum, koji nije dio stvarne domene koja se analizira.

Nadalje, neki od podataka su zastarjeli. Za nezavisne varijable je većina podataka bila iz 2013. i 2014. godine dok je transparentnost trenutno aktualna.

Također, problem koji se veže uz transparentnost je neinformiranost i nezainteresiranost građana. Kako bi istraživanja sličnog tipa dobila na značaju potrebno je informirati i motivirati građane za sudjelovanje u samom donošenju proračuna, te analiziranje trenutnog. Političari mogu zbuniti čak i racionalnog glasača, ali ne i potpuno informiranog glasača.

Međutim kako bi se građanima omogućilo sudjelovanje, potrebno je na vrijeme objaviti sve proračunske dokumente. Pravo na pristup informacijama i njihovu upotrebu pripada svim korisnicima na jednak način i pod jednakim uvjetima. Politička dužnost je informirati građane pravodobno, potpuno i točno jer su to odluke koje se donose u njihovo ime i trebale bi biti za boljitak njihovih lokalnih (regionalnih) jedinica.

Literatura

- [1] A. Alesina, R. Perotti , *Budget Deficits and Budget Institutions*, dostupno na <http://www.nber.org/chapters/c8021.pdf>
- [2] J. E. Alt, R. C. Lowry, *Transparency and Accountability: Empirical Results for US States*, travanj 2010., dostupno na <https://dash.harvard.edu/handle/1/9468172>
- [3] J. E. Alt, D. D. Lassen , *Transparency, Polical Polarization and Political Budget Cycles in OECD Countries*, 2006., dostupno na <http://www.jstor.org/stable/3694233>
- [4] A. Bajo, D. Jurlina Alibegović, *Javne financije lokalnih jedinica vlasti*, Školska knjiga, Zagreb, 2008.
- [5] B. Basrak, *Aktuarska matematika II, 4.dio*, dostupno na <https://web.math.pmf.unizg.hr/~bbsarak/pdf/files/AM2slides4dio.pdf>
- [6] B. Benito, F. Bastida , *Budget Transparency, Fiscal Performance and Political Turnout: An International Approach*, dostupno na <http://www.sciencedirect.com/science/article/pii/S0740624X14001178>
- [7] Deviance goodness of fit test for Poisson regression, dostupno na <http://thestatsgeek.com/2014/04/26/deviance-goodness-of-fit-test-for-poisson-regression/>
- [8] A. J. Dobson, Adrijan G. Bennett *An Introduction to Generalized Linear Models*, Taylor Francis Group, London, 1945.
- [9] A. Esteller-Moré, J. Polo Otero, *Fiscal Transparency, (Why) does your local government respond?*, 2012., dostupno na <http://www.tandfonline.com/doi/full/10.1080/14719037.2012.657839>
- [10] J. D. Gandía, M. C. Archidona, *Determinants of web site information by Spanish city councils*, dostupno na <http://dx.doi.org/10.1108/14684520810865976>
- [11] Generalizirani linearni model, dostupno na <https://web.math.pmf.unizg.hr/nastava/finprakt/vjezbe/fpvj9.pdf>
- [12] M. D. Guilermon, F. Bastida, B. Benito , *The Determinants of Local Government's Financial Transparency*, dostupno na <http://www.tandfonline.com/loi/flgs20>
- [13] Konačni rezultati za lokalne izbore, 1. krug, dostupno na <http://www.izbori.hr/2013Lokalni/rezult/krug-1/rezultati.html>
- [14] Konačni rezultati za lokalne izbore, 2. krug, dostupno na <http://www.izbori.hr/2013Lokalni/rezult/krug-2/rezultati.html>

- [15] Liang Ma, *What Drives Fiscal Transparency? Evidence from Provincial Governments in China*, dostupno na <https://www.researchgate.net/publication/228265328>
- [16] Ministarstvo uprave, dostupno na <https://uprava.gov.hr/o-ministarstvu/ustrojstvo/uprava-za-politicki-sustav-i-organizaciju-uprave/lokalna-i-podrucna-regionalna-samouprava/842>
- [17] P. McCullagh, J. A. Nelder, *Generalized Linear Models*, Chapman Hall CRC, London, 1952.
- [18] Opisna statistika, dostupno na <https://web.math.pmf.unizg.hr/nastava/stat/files/chap1novo.pdf>
- [19] Ostvarenje proračuna JLP(R)S za period 2010. - 2014., dostupno na <http://www.mfin.hr/hr/ostvarenje-proracuna-jlprs-za-period-2010-2014>
- [20] Ostvarenje proračuna JLP(R)S za period 2010. - 2014., dostupno na <http://www.mfin.hr/hr/ostvarenje-proracuna-jlprs-za-period-2010-2014>
- [21] K. Ott, M. Bronić, *Ostvarenje proračuna općina, gradova i županija u 2014.*, dostupno na <http://www.ijf.hr/upload/files/file/newsletter/98.pdf> (lipanj 2017.)
- [22] K. Ott, M. Bronić, M. Petrušić, B. Stanić *Proračunska transparentnost županija, gradova i općina: studeni 2015. – ožujak 2016.*, dostupno na <http://www.ijf.hr/upload/files/107.pdf>
- [23] K. Ott, M. Bronić, M. Petrušić, B. Stanić, *Proračunska transparentnost županija, gradova i općina: studeni 2016. – ožujak 2017.*, dostupno na <http://www.ijf.hr/upload/files/112.pdf>
- [24] M. P. Rodríguez Bolívar, M. del C. Caba Pérez, A. M. López-Hernández *Online Budget Transparency in OECD Member Countries and Administrative Culture*, dostupno na <http://journals.sagepub.com/doi/abs/10.1177/0095399713509238>
- [25] L. Sedmihradská, J. Haas, *Budget Transparency and Fiscal Performance: Do Open Budgets Matter?* dostupno na <https://is.vsfs.cz/repo/4803/SedmihradskaHaas.pdf>
- [26] Zakon o pravu na pristup informacijama, 2013., dostupno na <http://narodne-novine.nn.hr/clanci/sluzbeni/20130225403.html>

Dodatak

Podatci u Tablicama 30, 31 i 32 preuzeti su na način naveden u potpoglavlju 3.1 Podatci i oznake su u skladu s oznakama u Tablici 1.

Županije	Političar izabran u prvom krugu	Ljevica na vlasti	Koalicija na vlasti	Visokoobrazovani političari	Godine političara	Deficit/suficit	OLBI 2016
Bjelovarsko-bilogorska	0	0	1	1	52	0,055031236	5
Brodsko-posavska	1	0	1	1	44	0,075601595	4
Dubrovačko-neretvanska	1	0	1	1	67	0,055708074	5
Istarska	0	1	1	1	44	0,078769911	5
Karlovačka	0	0	1	1	52	-0,00772683	5
Koprivničko-križevačka	1	1	1	1	53	0,036659726	4
Krapinsko-zagorska	1	1	1	1	49	0,003823146	5
Ličko-senjska	1	0	1	0	52	0,115666017	5
Međimurska	0	0	1	1	33	0,0190746	5
Osječko-baranjska	0	0	1	1	59	-0,0037303	5
Požeško-slavonska	0	0	1	1	55	0,068473617	2
Primorsko-goranska	1	1	1	1	58	0,043784089	5
Sisačko-moslavačka	0	1	1	1	53	-0,05097707	5
Splitsko-dalmatinska	0	0	1	0	56	0,009556977	4
Šibensko-kninska	0	0	1	1	54	0,007371038	5
Varaždinska	0	1	1	1	47	0,105943038	5
Virovitičko-podravska	1	0	1	1	37	0,090646035	4
Vukovarsko-srijemska	1	0	1	1	64	0,067059772	4
Zadarska	0	0	1	1	56	0,056234591	5
Zagrebačka	1	0	1	1	55	0,028762779	5

Tablica 30: Podatci o hrvatskim županijama s varijablama korištenima u radu

Gradovi	Političar izabran u prvom krugu	Ljevica na vlasti	Koalicija na vlasti	Visokoobrazovani političari	Godine političara	Deficit/suficit	OLBI 2016
Bakar	1	0	1	0	52	0,174429158	3
Beli Manastir	0	1	1	1	63	0,235096765	4
Belišće	0	0	0	1	54	-0,119161022	4
Benkovac	0	0	1	1	53	0,031422311	3
Biograd na Moru	1	0	0	1	52	0,031841218	4
Bjelovar	0	0	1	1	65	-0,022230114	0
Buje	0	0	0	0	64	-0,074197532	4
Buzet	1	0	1	0	39	-0,128370504	3
Cres	0	1	1	0	45	-0,159017258	4
Crikvenica	0	0	1	1	58	0,226135697	3
Čabar	0	1	0	1	47	-0,151396891	4
Čakovec	0	1	1	0	61	-0,033917913	3
Čazma	0	0	0	1	60	0,185689383	1
Daruvar	0	0	1	0	66	0,034671507	4
Delnice	0	0	0	1	50	-0,178173615	3
Donja Stubica	1	0	0	1	55	0,117856173	4
Donji Miholjac	0	1	1	1	56	-0,01296361	4
Drniš	0	0	1	0	62	-0,032097719	4
Dubrovnik	0	0	1	1	57	0,02262685	3
Duga Resa	0	0	0	0	50	-0,007035752	3
Dugo Selo	0	0	0	1	45	-0,005162443	3
Đakovo	0	0	1	1	46	0,257851633	1
Đurđevac	1	1	1	0	52	0,010352391	4
Garešnica	0	0	1	1	48	0,053394004	5
Glina	1	0	1	0	61	-0,082759081	5
Gospić	0	1	1	0	60	-0,031533869	4
Grubišno Polje	0	1	0	1	51	-0,158339196	5
Hrvatska Kostajnica	1	1	1	1	55	-0,033435258	4
Hvar	1	0	1	1	53	-0,089408195	5
Ilok	1	1	1	1	59	0,045797095	4
Imotski	0	0	1	1	47	-0,011926138	2
Ivanec	1	1	1	1	44	-0,061520816	2
Ivanić-Grad	0	0	1	1	44	0,13201182	4
Jastrebarsko	1	1	1	1	47	-0,003968063	3
Karlovac	0	0	0	1	51	-0,030706545	3
Kastav	1	1	1	0	56	0,173428176	5
Kaštela	0	0	0	1	49	0,002973892	4
Klanjec	0	1	1	1	43	-0,182825206	5
Knin	0	1	1	1	58	-0,106748697	1
Komiža	0	0	1	0	42	0,008289247	3
Koprivnica	0	1	1	1	52	0,118098031	4
Korčula	0	0	1	0	37	-0,020972746	2

Kraljevica	0	0	1	0	55	0,059214981	4
Krapina	1	0	1	1	50	0,068252789	5
Križevci	0	1	1	1	45	0,051310394	5
Krk	0	1	1	0	54	-0,057629123	1
Kutina	0	0	1	0	58	0,066487474	4
Kutjevo	1	1	1	1	54	-0,163505955	5
Labin	0	0	1	0	48	0,023891146	2
Lepoglava	0	1	1	1	47	-0,219534576	4
Lipik	0	1	1	0	53	-0,006730751	5
Ludbreg	1	0	1	0	55	-0,136379029	3
Makarska	0	0	0	1	32	0,135063675	5
Mali Lošinj	1	0	1	0	50	0,22513317	4
Metković	0	0	0	1	47	0,056345412	5
Mursko Središće	1	0	0	0	60	0,131379552	3
Našice	0	0	1	1	52	-0,141727745	1
Nin	0	0	0	0	51	0,049741552	2
Nova Gradiška	0	1	1	0	38	0,032660072	2
Novalja	1	0	1	1	37	-0,040094604	3
Novi Marof	1	0	0	0	47	0,097145579	4
Novi Vinodolski	1	0	0	1	52	0,034005711	3
Novigrad	0	0	0	1	54	-0,428163122	4
Novska	0	0	0	1	68	-0,009870998	0
Obrovac	0	0	1	1	56	0,020887922	4
Ogulin	0	0	0	1	42	-0,041094889	3
Omiš	1	1	1	0	65	0,039840078	0
Opatija	1	0	1	0	58	0,015550584	3
Opuzen	1	0	1	0	61	0,100638778	2
Orahovica	0	1	1	1	51	-0,02474527	5
Oroslavje	0	1	0	1	69	0,022602827	2
Osijek	0	0	0	1	67	0,008926133	2
Otočac	1	0	1	1	48	0,140168885	0
Otok (Vinkovci)	1	0	1	1	56	-0,077509041	1
Ozalj	0	0	1	1	58	-0,285767238	1
Pag	1	0	0	1	51	-0,03794634	5
Pakrac	0	0	1	0	46	0,063489463	0
Pazin	0	1	1	0	60	0,046158038	1
Petrinja	1	0	1	0	38	-0,089675359	3
Pleternica	1	0	1	1	41	-0,025405095	1
Ploče	0	0	0	1	56	0,189242054	1
Popovača	0	0	0	1	51	-0,030383034	5
Poreč	0	0	1	1	43	0,109560328	1
Požega	0	1	1	1	34	0,063301968	4
Pregrada	0	0	1	1	49	0,090364643	1
Prelog	0	0	1	1	41	-0,079176377	1

Pula	0	1	1	1	43	0,026044967	5
Rab	0	1	1	1	59	0,17418076	5
Rijeka	1	0	0	1	53	0,057530874	0
Rovinj	1	1	1	1	45	0,081414362	1
Samobor	1	0	1	1	48	0,019821486	0
Senj	0	0	0	1	45	0,091009515	4
Sinj	0	1	1	1	41	-0,020074438	5
Sisak	1	0	0	0	49	0,016504375	4
Skradin	0	0	1	1	56	0,005250759	0
Slatina	0	0	0	1	55	0,109431807	4
Slavonski Brod	0	0	0	0	59	0,118890589	3
Slunj	1	0	1	0	56	0,007159848	4
Solin	0	1	1	1	58	0,075675431	3
Split	0	0	0	1	69	0,010354823	1
Stari Grad	0	1	1	1	37	0,196943217	3
Supetar	0	0	1	0	65	-0,313944059	5
Sveta Nedelja	0	0	0	0	65	-0,04464057	2
Sveti Ivan Zelina	0	1	1	0	46	0,109049907	3
Šibenik	0	0	1	1	61	-0,078216204	1
Trilj	0	0	0	1	42	-0,00591302	4
Trogir	0	0	1	1	56	0,134889319	1
Umag	1	1	1	1	58	0,007257458	0
Valpovo	1	0	1	1	38	0,013034423	1
Varaždin	0	1	1	1	44	0,034594298	4
Varaždinske Toplice	0	1	1	1	53	-0,092391121	5
Velika Gorica	1	0	1	1	47	-0,115948472	5
Vinkovci	0	0	1	1	54	0,06101338	4
Virovitica	1	0	1	1	46	-0,062603018	5
Vis	1	0	0	0	52	-0,055365104	5
Vodice	1	0	0	1	51	0,077492718	5
Vodnjan	1	0	1	1	49	0,014474785	2
Vrbovec	0	0	1	0	53	0,091890401	3
Vrbovsko	0	0	0	1	53	-0,014681663	1
Vrgorac	1	0	1	1	65	-0,099140557	4
Vrlika	0	0	0	0	57	0,046926621	4
Vukovar	0	0	1	1	42	-0,114818893	3
Zabok	0	1	1	0	68	-0,05707233	3
Zadar	0	0	1	1	58	0,06325824	2
Zagreb	0	0	0	1	61	0,017528902	4
Zaprešić	0	0	1	1	54	0,060039184	2
Zlatar	0	1	1	1	64	0,448164678	3
Županja	0	0	1	1	50	-0,003123983	5

Tablica 31: Podatci o hrvatskim gradovima s varijablama korištenima u radu

Općine	Političar izabran u prvom krugu	Ljevica na vlasti	Koalicija na vlasti	Visokoobrazovani političari	Godine političara	Deficit/suficit	OLBI 2016
Andrijaševci	0	0	1	1	0	-0,08537998	2
Antunovac	1	0	0	0	1	0,021382522	4
Babina Greda	0	1	1	0	0	0,211296746	4
Bale	1	0	0	0	0	0,079453079	2
Barban	1	1	0	1	0	0,28123538	3
Barilović	1	0	0	0	0	0,144929453	3
Baška	1	1	1	1	0	0,118570555	4
Baška Voda	1	0	0	1	0	0,337203117	1
Bebrina	1	0	1	0	0	0,128173666	4
Bedekovčina	0	0	0	0	1	0,015649768	4
Bedenica	1	0	1	1	0	-0,208769736	0
Bednja	1	1	1	1	0	0,066224036	2
Belica	1	1	0	0	1	0,139429241	4
Berek	1	0	0	0	0	-0,064169999	2
Beretinec	1	1	1	1	0	0,029419551	3
Bibinje	1	0	0	1	0	0,007220255	0
Bilice	0	0	0	0	0	-0,264367669	1
Bilje	0	0	0	0	1	0,158322618	0
Biskupija	1	0	0	0	0	-0,077685512	2
Bištra	1	0	0	0	1	0,022690071	3
Bizovac	1	0	0	0	0	0,048891169	5
Blato	1	0	0	1	0	-0,008001534	3
Bogdanovci	0	0	0	0	0	-0,028642103	1
Bol	0	1	0	0	0	-0,242778647	0
Borovo	1	0	0	1	0	-0,195698108	3
Bosiljevo	1	0	0	0	0	-0,122821715	2
Bošnjaci	0	0	0	0	0	-0,021079902	1
Brckovljani	1	0	0	0	0	0,135564477	0
Brdovec	1	1	1	0	1	-0,129210502	3
Brela	0	0	0	1	0	-0,129692445	2
Brestovac	1	0	0	0	1	-0,026098047	3
Breznica	1	0	1	0	0	0,603477133	0
Breznički Hum	1	1	1	0	0	0,120234265	3
Brinje	0	0	0	0	0	-0,090062723	3
Brod Moravice	1	0	0	1	0	0,032976415	2
Brodski Stupnik	1	0	1	0	0	0,366736015	4
Brtonigla	1	0	0	1	0	0,023026341	3
Budinščina	1	0	1	0	0	0,072947947	2
Bukovlje	0	1	1	0	0	0,241001949	4
Cerna	1	0	1	0	0	0,163553183	1
Cernik	1	0	0	0	1	0,074809058	3
Cerovlje	1	0	0	0	1	-0,187858649	1
Cestica	0	1	1	0	1	-0,138789745	3
Cetingrad	0	0	0	1	0	-0,052963273	2

Cista Provo	1	0	0	0	0	-0,090010026	1
Civljane	1	0	0	0	0	0,072275471	3
Crnac	1	0	1	0	0	-0,255895786	3
Čačinci	1	0	0	0	1	0,038918809	1
Čađavica	1	0	1	0	0	-0,23197947	3
Čaglin	0	1	0	0	1	-0,11813037	2
Čavle	1	1	1	0	0	0,080633573	3
Čeminac	1	0	0	1	0	-0,038426502	1
Čepin	0	0	1	0	0	0,134667392	0
Darda	0	0	0	0	0	0,221485195	0
Davor	1	0	0	1	0	-0,076201871	1
Dekanovec	1	0	1	0	0	-0,056550542	4
Desinić	1	0	1	0	0	0,169638489	3
Dežanovac	0	1	0	0	0	-0,419538984	2
Dicmo	0	0	1	0	1	-0,048580128	0
Dobrinj	1	0	0	0	0	0,038903072	3
Domašinec	1	0	0	0	0	0,223186184	2
Donja Dubrava	0	0	1	0	0	-0,038480597	2
Donja Motičina	1	0	0	0	0	0,38453694	2
Donja Voća	0	0	0	0	0	0,21595915	1
Donji Andrijevi	0	0	0	0	0	-0,048224349	3
Donji Kraljevec	0	0	0	1	0	0,077935415	3
Donji Kukuruzari	1	0	1	0	1	0,011140304	2
Donji Lapac	1	0	0	1	0	-0,118094235	1
Donji Vidovec	1	1	1	0	0	-0,236234514	2
Dragalić	1	0	0	0	0	-0,061734437	2
Draganić	0	0	1	1	0	-0,033087137	3
Draž	1	0	0	1	0	0,062270658	0
Drenovci	0	0	1	1	0	-0,140637996	3
Drenje	1	0	1	1	0	0,248123731	2
Drnje	1	0	1	0	0	0,116902497	4
Dubrava	1	1	1	1	0	-0,001667247	2
Dubravica	1	0	0	0	0	-0,144993197	1
Dubrovačko primorje	1	0	0	1	0	-0,210341424	1
Dugi Rat	0	0	0	1	0	0,106856064	0
Dugopolje	1	0	0	1	0	0,254125285	1
Dvor	0	0	0	0	1	0,008854615	1
Đelekovec	1	0	1	1	0	0,001779128	3
Đulovac	1	0	0	0	0	0,104224106	4
Đurđenovac	0	0	1	1	0	0,239625589	0
Đurmanec	0	0	1	1	0	-0,036363125	1
Erdut	1	0	0	0	0	-0,054541497	3
Ernestinovo	1	0	0	1	0	0,068658646	3
Ervenik	1	0	0	0	1	-0,079334337	2
Farkaševac	1	0	0	0	0	-0,065330735	1
Fažana	1	1	1	1	0	-0,042681583	4

Ferdinandovac	0	0	0	1	0	-0,00206362	3
Feričanci	0	0	1	0	0	0,073773919	3
Funtana	0	0	0	0	1	0,026813995	3
Fužine	0	0	0	0	1	-0,008986192	0
Galovac	1	0	1	1	0	-0,187906171	1
Garčin	1	0	0	1	0	-0,035289136	3
Generalski Stol	1	0	0	1	0	-0,095769078	4
Gola	1	0	0	1	0	0,075674689	3
Goričan	1	1	1	1	0	0,001557437	3
Gorjani	1	0	1	0	0	0,145890276	0
Gornja Rijeka	0	1	1	0	1	-0,302988081	1
Gornja Stubica	1	1	0	1	0	-0,024910952	0
Gornja Vrba	0	0	0	1	0	0,126957154	3
Gornji Bogičevci	1	0	0	1	0	0,132517547	0
Gornji Knežinec	1	0	1	0	1	0,587965677	3
Gornji Mihaljevec	1	0	0	0	1	0,161675549	3
Gračac	0	0	1	1	0	-0,020189676	4
Gračišće	1	0	0	0	0	0,2887782	4
Gradac	1	0	0	0	0	0,041130807	3
Gradec	0	0	0	1	0	0,01425905	2
Gradina	1	0	1	0	0	-0,102631674	3
Gradište	1	0	1	0	0	-0,010806607	1
Grožnjan	1	0	0	1	0	0,401962844	4
Gundinci	0	0	0	0	0	0,383178552	2
Gunja	0	1	1	1	0	0,060251824	2
Gvozd	0	0	0	1	0	0,078988296	1
Hercegovac	1	1	1	1	0	0,246759712	3
Hlebine	1	0	1	0	0	-0,078975907	4
Hrašćina	0	0	1	0	0	0,049206003	0
Hrvace	1	0	0	1	0	-0,078824193	0
Hrvatska Dubica	0	0	0	0	0	-0,063269524	3
Hum na Sutli	1	1	0	1	0	0,030910878	2
Ivankovo	1	0	0	1	0	0,188912823	1
Ivanska	0	0	0	1	0	0,000651149	1
Jagodnjak	0	0	1	1	0	-0,01066759	3
Jakovlje	1	1	0	1	0	0,137002254	0
Jakšić	1	0	1	1	0	0,511405357	1
Jalžabet	1	0	1	1	0	-0,864422901	0
Janjina	1	0	0	0	0	-0,027924916	1
Jarmina	0	0	1	0	0	-0,117887268	3
Jasenice	1	0	0	0	1	0,102061728	0
Jasenovac	1	0	1	0	0	-0,113580145	2
Jelenje	1	0	0	1	0	-0,189004438	0
Jelsa	0	0	0	1	0	-0,048715568	1
Jesenje	1	1	1	0	0	-0,190630206	2
Josipdol	1	0	1	0	1	-0,010280514	4

Kali	0	1	1	1	0	-0,01461122	4
Kalinovac	1	0	0	1	0	-0,165777992	4
Kalnik	1	1	1	0	1	-0,263544262	2
Kamanje	1	1	0	1	0	0,125618652	4
Kanfanar	1	0	0	1	0	0,02061852	2
Kapela	1	0	0	0	1	0,210176463	2
Kaptol	1	0	1	0	1	-0,652276305	2
Karlobag	1	0	0	1	0	-0,453421896	0
Karojba	1	0	0	0	0	-0,036598053	2
Kaštelir - Labinci	1	0	0	0	0	-0,776685385	0
Kijevo	1	0	0	1	0	0,09448439	2
Kistanje	1	0	0	0	0	0,068207517	5
Klakar	0	0	0	1	0	-0,03278608	3
Klana	0	0	0	1	0	0,162524223	3
Klenovnik	0	1	1	1	0	0,257457918	0
Klinča Sela	0	0	0	1	0	0,0549938	0
Klis	0	0	1	0	0	-0,135647671	2
Kloštar Ivanić	0	1	1	0	0	-0,235406864	4
Kloštar Podravski	0	0	0	0	0	0,056080616	0
Kneževi Vinogradi	1	0	0	1	0	-0,016002637	2
Kolan	1	0	0	0	0	0,292552722	0
Konavle	0	0	1	0	0	0,325532532	5
Končanica	0	0	0	0	0	-0,016361902	2
Konjščina	1	0	1	0	0	0,007467926	4
Koprivnički Bregi	1	0	0	1	0	0,132337622	3
Koprivnički Ivanec	0	0	0	0	0	-0,255253053	2
Kostrena	0	1	1	1	0	0,003373746	5
Koška	1	0	0	1	0	0,267607004	3
Kotoriba	0	1	0	0	0	-0,016777186	3
Kraljevec na Sutli	0	0	0	0	0	-0,054175917	0
Krapinske Toplice	0	0	1	0	1	-0,05612167	4
Krašić	1	0	0	1	0	-0,110463495	3
Kravarско	1	0	0	0	0	-0,126630716	2
Križ	0	1	0	1	0	0,320292519	4
Krnjak	0	0	0	1	0	0,093322793	2
Kršan	0	0	0	0	1	0,030655292	4
Kukljica	0	0	0	0	0	0,05054599	1
Kula Norinska	1	0	1	1	0	-0,003920094	2
Kumrovec	1	1	1	0	0	-0,118928056	1
Lanišće	1	0	0	0	0	-0,013600575	2
Lasinja	1	0	0	0	0	0,0001184	3
Lastovo	0	0	0	0	0	-0,081368535	1
Lećevica	1	0	0	1	0	0,157152812	2
Legrad	0	1	0	1	0	0,582655057	4
Lekenik	0	0	0	0	1	-0,228035433	1
Levanjska Varoš	0	0	0	0	0	0,062892321	0

Lipovljani	1	1	1	1	0	-0,130615451	4
Lišane Ostrovičke	1	0	0	1	0	-0,205514201	0
Ližnjan	1	0	0	1	0	-0,282707904	3
Lobor	0	1	1	1	0	-0,014576136	3
Lokve	0	1	1	0	0	-0,099674502	0
Lokvičiči	1	0	0	0	1	-0,012636661	0
Lopar	1	0	1	1	0	0,09876068	1
Lovas	1	0	1	1	0	0,035555394	2
Lovinac	1	0	1	0	0	-0,229151291	3
Lovran	0	0	1	1	0	-0,090854009	5
Lovreć	1	0	0	1	0	0,057837569	1
Luka	1	0	0	1	0	0,532948194	3
Lukač	1	0	0	0	0	-0,006537702	3
Lumbarda	1	0	0	1	0	-0,145009192	3
Lupoglav	1	0	0	0	0	0,239087682	3
Ljubešćica	1	0	0	0	0	0,001637382	3
Mače	0	0	1	0	0	0,115861376	3
Magadenovac	1	0	1	0	0	-0,098982409	2
Majur	1	0	0	1	0	0,081713997	2
Mala Subotica	0	0	0	0	1	0,341684693	3
Mali Bukovec	1	0	1	1	0	0,115309342	3
Malinska-Dubašnica	1	1	1	0	0	0,062053833	0
Marčana	0	0	0	0	0	-0,101926558	2
Marija Bistrica	0	0	0	0	1	0,004952945	0
Marija Gorica	1	0	0	0	0	-0,174282437	1
Marijanci	1	0	1	0	0	0,446430344	1
Marina	0	0	0	0	0	0,01957063	1
Markušica	1	0	0	0	1	-0,048678824	2
Martijanec	1	1	1	0	0	0,079847758	4
Martinska Ves	0	0	1	1	0	0,323612727	3
Maruševac	1	0	1	0	0	0,266856067	3
Matulji	0	1	1	0	1	-0,029007779	4
Medulin	1	0	0	1	0	-0,016114728	3
Mihovljan	1	0	1	0	0	0,162248512	0
Mikleuš	0	0	1	0	0	-0,136629578	0
Milna	0	1	0	1	0	0,276939342	1
Mljet	0	0	0	1	0	0,002117069	2
Molve	0	0	0	1	0	-0,187582586	4
Mošćenička Draga	1	0	1	1	0	0,450210449	4
Motovun	1	0	0	0	0	-0,487631372	3
Mrkopalj	1	1	0	0	0	-0,045905839	2
Muč	1	0	0	0	0	0,19854357	3
Murter	0	0	1	0	0	0,178102192	1
Nedelišće	1	1	1	0	0	0,031338238	1
Negoslavci	1	0	0	0	1	0,073036687	1
Nerežišća	1	0	1	1	0	0,135798999	0

Netretić	1	0	1	0	0	-0,071905279	4
Nijemci	0	0	0	0	0	-0,079495253	3
Nova Bukovica	1	0	1	0	0	-0,326232368	1
Nova Kapela	0	0	0	0	0	0,175223292	0
Nova Rača	0	0	0	0	0	0,008885051	0
Novi Golubovec	1	0	0	0	0	-0,061184366	0
Novigrad	1	0	0	1	0	-0,428163122	2
Novigrad Podravski	1	0	1	0	0	0,249685721	2
Novo Virje	1	0	1	1	0	0,114777095	3
Nuštar	0	0	0	0	0	-0,038559948	3
Okrug	0	0	0	0	1	0,002393152	4
Okučani	1	0	0	0	0	0,014436964	1
Omišalj	0	1	1	1	0	-0,017715039	3
Oprisavci	0	1	0	0	0	-0,047972489	2
Oprtalj	1	0	1	0	0	0,458936474	2
Orebić	0	0	0	0	1	-0,095242371	2
Orehovica	1	1	0	0	0	0,07800888	5
Oriovac	1	0	0	0	0	-0,112270664	1
Orle	1	0	0	0	0	-0,004021484	0
Otok	0	0	0	0	0	-0,067927804	1
Pakoštane	0	0	1	0	0	0,246712392	1
Pašman	0	0	0	1	0	0,449495764	0
Perušić	1	0	1	0	0	-0,121582725	3
Peteranec	0	0	0	0	1	0,244455805	2
Petlovac	0	1	1	0	0	0,387250901	2
Petrijanec	1	0	1	0	0	-0,052180887	1
Petrijevci	1	0	0	1	0	0,141213533	3
Petrovsko	0	0	1	1	0	0,197955678	1
Pićan	0	0	0	0	0	-0,247697045	3
Pirovac	0	1	0	0	1	-0,134607697	4
Pisarovina	1	0	0	0	1	-0,117010698	4
Pitomača	1	0	1	0	0	0,095427863	4
Plaški	0	1	1	0	0	0,112617691	0
Plitvička Jezera	0	0	1	0	0	-0,512347877	1
Podbablje	0	0	0	1	0	0,272376902	0
Podcrkavlje	0	0	0	0	0	-0,105160123	3
Podgora	1	0	0	0	0	0,077233951	2
Podgorač	1	1	1	0	0	0,24717257	3
Podravska Moslavina	0	0	0	0	0	-0,101968797	0
Podravske Sesvete	1	0	0	0	0	-0,087582234	3
Podstrana	0	0	1	1	0	-0,030990493	1
Podturen	1	0	1	0	0	0,093855644	3
Pojezerje	1	0	1	0	0	-0,750097965	0
Pokupsko	1	0	0	1	0	-0,983279257	1
Polača	0	0	0	0	0	0,085794206	2
Poličnik	1	0	0	0	1	-0,085664561	2

Popovac	0	0	0	1	0	0,100669146	3
Posedarje	1	0	0	0	0	-0,058207561	1
Postira	1	0	0	1	0	0,059351645	2
Povljana	1	0	0	0	1	-0,060028019	0
Preko	1	0	1	0	1	-0,431972584	2
Preseka	0	0	0			0,168710405	1
Prgomet	1	0	0	0	0	0,014851043	0
Pribislavec	1	1	1	1	0	0,000789992	2
Primorski Dolac	1	0	0	0	0	-0,339680778	3
Primošten	1	0	0	0	0	0,466857416	2
Privlaka (Vinkovci)	1	0	1	0	0	0,23550453	4
Privlaka (Zadar)	0	0	0	1	0	0,059733634	1
Proložac	1	0	0	0	1	-0,18312335	0
Promina	1	0	0	0	1	-0,065717318	3
Pučišća	1	0	1	0	1	-0,050954697	1
Punat	0	1	1	0	0	-0,067281263	4
Punitovci	1	0	1	0	0	0,145564362	0
Pušća	1	0	0	1	0	-0,160482931	2
Radoboj	1	1	1	0	1	-0,127649786	5
Rakovec	1	0	0	1	0	0,016307971	3
Rakovica	1	0	0	0	0	0,031325531	4
Rasinja	0	1	0	1	0	0,024223523	0
Raša	1	0	0	1	0	-0,038187285	4
Ravna Gora	1	1	1	0	0	0,053207697	3
Ražanac	0	0	0	0	1	0,055091273	1
Rešetari	0	0	0	0	0	0,041462404	1
Ribnik	1	1	1	1	0	0,230249156	4
Rogoznica	1	0	0	1	0	0,180932084	2
Rovišće	1	0	0	0	0	0,156900824	0
Rugvica	0	0	0	1	0	-0,027848897	0
Runovići	1	0	0	0	1	-0,005808839	0
Ružić	1	0	1	0	0	0,035525665	4
Saborsko	1	0	1	0	0	-0,140245518	2
Sali	1	1	1	0	1	-0,065280214	2
Satnica Đakovačka	0	1	1	0	0	-0,042200126	3
Seget	1	0	0	1	0	0,068717532	3
Selca	0	0	0	0	0	-0,10106093	4
Selnica	0	1	1	0	0	0,000506619	2
Semeljci	1	0	0	0	0	0,189103807	2
Severin	0	0	0	0	0	0,072277678	0
Sibinj	1	0	0	0	1	0,212881683	0
Sikirevci	0	0	0	0	0	-0,11898419	1
Sirač	1	0	0	0	1	-0,24102265	3
Skrad	1	0	1	1	0	-0,009395256	2
Slavonski Šamac	0	1	0	1	0	-0,042758678	3
Slivno	1	0	1	1	0	0,086069823	2

Smokvica	0	0	1	0	0	-1,05252438	2
Sokolovac	1	0	0	1	0	0,057446013	2
Sopje	0	0	1	0	0	0,057130581	1
Sračinec	1	1	1	0	0	0,023437417	2
Stankovci	1	0	0	0	0	-0,456726414	0
Stara Gradiška	1	0	0	1	0	0,008976035	4
Stari Jankovci	0	0	0	0	1	-0,006716426	4
Stari Mikanovci	0	1	1	0	0	0,024625628	2
Starigrad	1	0	0	1	0	0,196943217	4
Staro Petrovo Selo	0	0	0	0	0	0,220660713	3
Ston	1	0	0	0	1	-0,153337085	3
Strahoninec	1	0	1	0	1	0,324522821	4
Strizivojna	0	0	0	1	0	0,394037399	1
Stubičke Toplice	1	0	1	0	0	-0,000351468	4
Stupnik	0	0	0	1	0	-0,148995965	3
Sučuraj	0	0	1	1	0	-0,239600592	0
Suhopolje	0	0	1	0	0	-0,161178316	3
Sukošan	1	0	0	0	0	0,060836624	4
Sunja	0	0	1	0	0	-0,119186426	4
Sutivan	0	0	0	1	0	0,196705035	0
Sveta Marija	1	0	0	0	0	-0,156594767	3
Sveta Nedelja	0	0	1	0	1	0,040342241	4
Sveti Đurđ	1	1	1	0	0	0,020784252	1
Sveti Filip i Jakov	0	0	0	0	0	-0,026056655	3
Sveti Ilija	1	0	0	1	0	-0,104720157	1
Sveti Ivan Žabno	0	0	0	0	0	0,245323632	2
Sveti Juraj na Bregu	1	1	1	0	1	-0,344791068	2
Sveti Križ Začretje	0	1	1	1	0	0,071767469	5
Sveti Lovreč	1	0	0	1	0	-0,035793691	3
Sveti Martin na Muri	1	1	1	0	0	0,187123731	3
Sveti Petar Orehovec	0	0	0	1	0	0,448711612	2
Sveti Petar u Šumi	1	0	0	1	0	0,694856013	1
Svetvinčenat	1	1	1	0	0	0,085082489	1
Šandrovac	1	0	0	0	0	0,094423676	2
Šenkovec	1	1	1	1	0	0,09213014	2
Šestanovac	0	0	0	0	0	0,186023608	1
Škabrnja	1	0	1	0	0	-0,006456483	0
Šodolovci	1	0	0	1	0	-0,096167567	3
Šolta	1	0	0	0	1	0,181680931	1
Špišić Bukovica	0	0	1	0	1	-0,038110038	0
Štefanje	1	0	1	0	0	0,005968834	0
Štitar	0	0	0	0	0	0,141415198	3
Štrigova	0	1	0	0	1	-0,028862342	2
Tar-Vabriga	0	0	0	0	0	-0,090265148	4
Tinjan	1	1	0	1	0	0,02808972	0
Tisno	1	1	1	0	0	0,067831873	2

Tkon	1	0	0	1	0	-0,150699849	1
Tompojevci	1	0	0	1	0	-0,016779718	3
Topusko	0	0	1	1	0	0,040657047	3
Tordinci	0	1	1	0	0	-0,033753539	0
Tounj	1	0	0	0	1	0,255364809	3
Tovarnik	0	0	0	1	0	0,113522863	2
Tribunj	1	0	1	1	0	0,007085849	3
Trnava	0	0	0	1	0	0,306497855	0
Trnovec Bartolovečki	0	1	1	0	0	0,010509164	3
Trpanj	1	0	1	1	0	-0,043858846	4
Trpinja	0	0	0	0	1	-0,058223183	3
Tučepi	1	0	1	0	0	0,136651719	0
Tuhelj	1	0	1	0	1	-0,19367691	2
Udbina	1	0	1	1	0	0,116985914	4
Unešić	1	0	0	0	1	-0,318111484	3
Vela Luka	0	1	1	1	0	0,06497197	0
Velika	1	0	0	1	0	0,134533303	3
Velika Kapanica	1	0	0	1	0	0,011450231	0
Velika Ludina	1	0	1	0	0	-0,331375906	2
Velika Pisanica	1	1	1	0	0	0,118647434	1
Velika Trnovitica	1	0	1	0	0	0,055039875	1
Veliki Bukovec	1	1	1	0	1	0,16972082	1
Veliki Grđevac	0	1	0	0	0	-0,046510298	2
Veliko Trgovišće	0	0	0	0	1	-0,022867306	2
Veliko Trojstvo	1	0	0	1	0	0,083274414	1
Vidovec	1	0	1	0	1	-0,036082564	2
Viljevo	1	0	0	0	0	0,000289958	2
Vinica	1	0	0	0	0	0,048885122	2
Vinodolska općina	0	1	1			-0,097824282	4
Vir	0	0	0	0	0	0,52571211	3
Virje	1	0	1	0	0	-0,001815261	2
Visoko	1	0	0	0	0	0,295485239	0
Viškovci	0	0	0	0	0	-0,074458672	0
Viškovo	0	1	1	1	0	-0,079412752	4
Višnjan	0	0	0	1	0	0,007981851	1
Vižinada	1	1	0	1	0	-0,514618772	2
Vladislavci	0	0	0	0	0	-0,093055141	3
Voćin	1	0	1	1	0	-0,46973984	2
Vođinci	0	0	0	0	0	-0,102365338	3
Vojnić	0	0	0	1	0	0,144641351	3
Vratišinec	1	1	1	0	0	0,041999642	2
Vrbanja	0	0	1	0	0	0,000364357	2
Vrbje	1	0	0	0	1	0,105668661	1
Vrbnik	1	0	0	1	0	-0,189939671	4
Vrhovine	1	0	0	0	1	-0,123764669	2
Vrpolje	1	0	0	0	0	0,313651992	3

Vrsar	1	0	0	1	0	0,199569229	1
Vrsi	1	0	0	1	0	0,071992281	0
Vuka	0	0	0	1	0	-0,271011411	4
Zadvarje	1	0	0	1	0	-0,159312831	1
Zagorska Sela	1	0	0	0	0	-0,03752358	0
Zagvozd	1	0	0	0	0	0,15429099	1
Zažablje	0	0	0	0	0	0,046450444	0
Zdenci	0	0	1	0	1	-0,054301083	1
Zemunik Donji	1	0	0	1	0	-0,42415664	2
Zlatar Bistrica	1	1	1	0	0	-0,028031592	1
Zmijavci	1	0	1	0	0	0,222007436	0
Zrinski Topolovac	0	1	1	0	0	-0,129034379	0
Žakanje	1	0	1	0	0	0,193676694	2
Žminj	0	0	0	0	0	0,07218778	3
Žumberak	1	0	0	0	0	-0,049659248	0
Župa dubrovačka	1	0	0	0	0	-0,010120477	1

Tablica 32: Podatci o hrvatskim općinama s varijablama korištenima u radu

Sažetak

Ovaj rad bavi se utjecajem odabranih varijabli na proračunsku transparentnost lokalnih (regionalnih) jedinica. Proračun je jedan od najvažnijih izvora informacija koji omogućuje pregled trenutnog financijskog stanja promatranih jedinica. Kako bi se provjerile zadane pretpostavke provodi se Poissonova regresija. U radu se koriste odrednice proračunske transparentnosti 428 općina, 127 gradova te 20 županija. Odabrane varijable su političari izabrani u prvom krugu izbora, ljevica na vlasti, koalicija na vlasti, visokoobrazovani političari, dob političara te deficit/ suficit. Pretpostavke rada su da varijable političar izabran u prvom krugu i koalicija na vlasti negativno utječu na transparentnost, a varijable ljevica na vlasti, dob političara i deficit pozitivno utječu na transparentnost. Na temelju dobivenih rezultata može se zaključiti da ljevica na vlasti pozitivno utječe na transparentnost općina, dok se ostale varijable nisu pokazale statistički značajnim.

Summary

This thesis deals with the influence of selected variables on the budget transparency of local (regional) units. The budget is one of the most important information that allows you to review the current financial position of the observed units. In order to check the default assumptions, Poisson's regression is performed. This paper uses budget transparency constraints for 428 municipalities, 127 cities and 20 counties. The selected variables are politicians elected in the first round of elections, the left-wing government, the coalition of senior, educated politicians, the age of politicians, the deficit / surplus. The assumptions of the thesis are that the variable "politician elected in the first round" and the "ruling coalition" negatively affect transparency, the "ruling" variable, the age of politicians and the deficit positively influence transparency. On the basis of the obtained results, it can be concluded that the leader in the government has a positive influence on the transparency of the municipality, while the other variables have not been shown as statistically significant.

Životopis

Andelka Oroz rođena je 23. rujna 1991. godine u Derventi. Završava osnovnu školu dr. Vinka Žganca te potom upisuje X. gimnaziju "Ivan Supek". Godine 2010. upisuje Preddiplomski studij Matematike na Prirodoslovno matematičkom fakultetu Sveučilišta u Zagrebu. Preddiplomski studij Matematika, nastavnički smjer završava 2014. godine te iste godine upisuje diplomski sveučilišni studij Financijske i poslovne matematike. Za javne financije i problem transparentnosti zainteresirala se na predmetu Ekonomika javnog sektora koji su predavali prof. Katarina Ott i dr. Ivica Urban. Trenutno je zaposlena u Otp leasing-u.