# UTJECAJ POREZNOG SUSTAVA NA KORUPCIJU U ZEMLJAMA EUROPSKE UNIJE

**Šeparović, Mateo**

**Master's thesis / Diplomski rad**

**2016**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **University of Split, Faculty of economics Split / Sveučilište u Splitu, Ekonomski fakultet**

*Permanent link / Trajna poveznica:* https://urn.nsk.hr/urn:nbn:hr:124:386471

*Rights / Prava:* In copyright / Zaštićeno autorskim pravom.

*Download date / Datum preuzimanja:* **2024-04-19**

*Repository / Repozitorij:*

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

**SVEUČILIŠTE U SPLITU**

**EKONOMSKI FAKULTET**

**DIPLOMSKI RAD**

# UTJECAJ POREZNOG SUSTAVA NA KORUPCIJU U ZEMLJAMA EUROPSKE UNIJE

**Mentor:**

**doc. dr. sc. Josip Visković**

**Student:**

**Mateo Šeparović, univ. bacc.**

**Split, rujan 2016.**

# SADRŽAJ:

1. UVOD ..... 3
1.1. Problem i predmet istraživanja ..... 3
1.2. Ciljevi, struktura i hipoteze istraživanja ..... 5
1.3. Metode istraživanja ..... 7
1.4. Doprinos istraživanja ..... 8
2. POJAM, ČIMBENICI I TROŠKOVI KORUPCIJE ..... 9
2.1. Definicija, podjela i pojavni oblici korupcije ..... 9
2.2. Čimbenici korupcije ..... 13
2.2.1. Izravni čimbenici ..... 13
2.2.2. Neizravni čimbenici ..... 17
2.3. Ekonomski troškovi korupcije ..... 20
2.4. Mjerenje korupcije ..... 24
2.4.1. CPI i WGI indeksi ..... 26
2.4.2. Problemi s mjerenjem korupcije ..... 28
3. PREGLED EMPIRIJSKIH ISTRAŽIVANJA ODNOSA POREZNOG SUSTAVA I KORUPCIJE ..... 30
3.1. Složenost poreznog sustava i korupcija ..... 30
3.2. Porezna struktura i korupcija ..... 33
4. EMPIRIJSKO ISTRAŽIVANJE UTJECAJA POREZNOG SUSTAVA NA KORUPCIJU ..... 36
4.1. Podaci i metodologija istraživanja ..... 36
4.2. Utjecaj složenosti poreznog sustava na korupciju ..... 41
4.3. Utjecaj porezne strukture na korupciju ..... 44
5. ZAKLJUČAK ..... 47
LITERATURA ..... 49
POPIS TABLICA ..... 52
POPIS SLIKA ..... 52
PRILOZI ..... 53
SAŽETAK ..... 57
SUMMARY ..... 58

# 1. UVOD

## 1.1. Problem i predmet istraživanja

Posljednjih desetljeća, fenomen poznat kao korupcija privlači mnogo pozornosti. U različitim zemljama – velikima i malima, razvijenima i u razvoju, tržišno orijentiranima ili ne, zbog optužbi za korupciju padale su vlade, političari (uključujući predsjednike država i premijere) su odstupali sa svojih položaja, a u nekim slučajevima čitave političke kaste su se mijenjale. Korupcija svakako nije nov fenomen: u pisanoj literaturi o njoj se raspravljalo još prije dvije tisuće godina, a spominjala se i u djelima čuvenih umjetnika, poput Dantea ili Shakespearea (Tanzi 1998, str. 4).

Definiranje korupcije nije jednostavno zbog raznolikosti njezinih pojavnih oblika te prikrivenosti od pogleda javnosti. Ipak, jedna od najčešćih i najsažetijih definicija, koju koriste i Svjetska banka te *Transparency International*, glasi da je korupcija „**zlouporaba javnog položaja radi privatne koristi**“ (IMF 2016, str. 3). Ova korist može ili ne mora biti financijska: poanta je da je javni položaj zlorabljen, a to znači da je službenikova odluka donesena iz razloga koji nisu navedeni kao relevantni od strane pravnog ili administrativnog okvira kojeg službenik provodi. Korupcija može djelovati i na višoj, zakonodavnoj razini: kada su zakonodavci toliko podčinjeni privatnim interesima da njihove odluke zanemaruju javni interes, dolazi do *de facto* privatizacije javne politike.

Troškovi korupcije su značajni: godišnji trošak isključivo mita procjenjuje se na približno 2% svjetskog BDP-a (IMF 2016, str. 5). Korupcija također negativno utječe na kanale uključivog rasta (eng. *inclusive growth*), tj. rasta čiju korist dijeli populacija, kao što su makro-financijska stabilnost, javne i privatne investicije, akumulacija ljudskog kapitala te ukupna faktorska produktivnost. Niske razine uključivog rasta također rezultiraju rastom korupcije, što zatvara negativan ciklus koji dalje produbljuje fenomen korupcije.

Imajući sve navedeno u vidu, razumljivo je da su uzroci korupcije česta tema rasprava i istraživanja. Pritom, s obzirom da se radi o izvoru državnog financiranja, odnos poreznog sustava i korupcije privlači posebnu pozornost. Naime, poznato je da korupcija negativno utječe na prihode od poreza u određenoj državi, i to na više načina (Nawaz 2010, str. 2-3): osim najizravnijeg načina, a to je smanjenje sadašnjih prihoda, korupcija također može umanjiti i buduće porezne prihode, korodirati porezni moral stanovništva, izobličiti poreznu

strukturu na način da se pogoduje „ukorijenjenim elitama," potaknuti rast sive ekonomije, umanjiti produktivne javne investicije poput cestovne infrastrukture, zdravstva ili obrazovanja itd.

Za razliku od korupcije, oporezivanje je legitiman oblik ekstrakcije resursa iz gospodarstva. Međutim, smatra se da pretjerano oporezivanje, iako možda donosi koristi u vidu veće količine javnih dobara, može negativno utjecati na gospodarski rast. Također, može potaknuti i utaju poreza u svrhu pokušaja smanjenja poreznog opterećenja pojedinca. Tanzi (1998, str. 11-12) navodi neke od čimbenika rasta korupcije u poreznom sustavu: dvosmislenost ili nerazumljivost poreznih propisa, potreba čestog kontakta s poreznim vlastima pri plaćanju poreza, niske plaće službenika porezne administracije, ignoriranje ili nekažnjavanje korupcije u prošlosti (loš primjer), manjak transparentnosti administrativnih procedura, velik diskrecijski autoritet poreznih službenika nad važnim odlukama, te općenito slaba kontrola države nad djelatnicima svoje administracije.

Iz navedenoga se nameće zaključak da država može i treba imati važnu ulogu u suzbijanju korupcije, jer ona utječe na većinu spomenutih čimbenika rasta korupcije: porezne propise odnosno njihovu razumljivost, visinu plaća poreznih službenika, sankcioniranje korupcije, transparentnost administracije itd. Korupcija je, dakako, složen fenomen i nikad se neće moći u cijelosti suzbiti, no na nekim je područjima lakše djelovati. O tome kako porezni sustav djeluje na korupciju još uvijek vlada manjak empirijskih dokaza, bez kojih se ne može zaključiti postoji li mogućnost suzbijanja korupcije reformama u poreznom sustavu (Nawaz 2010, str. 4). Ipak, određena istraživanja počela su se značajnije provoditi tek u zadnje vrijeme.

U svakom slučaju, postavlja se pitanje koje je preduvjete potrebno ispuniti u prostoru porezne politike da se pokuša smanjiti nivo korupcije u zemlji, što čini problem ovog istraživanja. Kao što proizlazi iz spomenutog problema, u ovome radu istraživat će se utjecaj poreznog sustava na korupciju, što čini i predmete ovog istraživanja. Konkretnije istraživanje usmjerit će se ka zemljama članicama Europske Unije tijekom zadnjeg desetljeća, a aspekti poreznog sustava koji će biti uključeni u istraživanje bit će **složenost poreznog sustava** te **omjer direktnih i indirektnih poreza**.

## 1.2. Ciljevi, struktura i hipoteze istraživanja

S teorijskog stajališta, cilj rada jest opisati teorijske aspekte korupcije: pojam odnosno definiciju te podjelu korupcije, čimbenike koji izravno ili neizravno doprinose korupciji, ekonomske troškove korupcije po vladine funkcije i institucije, društvo itd., te metode mjerenja korupcije. Nadalje, u nastavku je cilj dati pregled rezultata dosadašnjih empirijskih istraživanja odnosa poreznog sustava i korupcije.

S empirijskog stajališta, cilj ovoga istraživanja jest utvrditi postoji li povezanost između složenosti poreznog sustava odnosno porezne strukture i korupcije, u zemljama članicama Europske Unije.

Diplomski rad sastojat će se od pet poglavlja, kako slijedi.

1. U **prvom**, **uvodnom poglavlju**, definirat će se problem i predmet istraživanja, elaborirat će se istraživačke hipoteze te navesti znanstvene metode koje će se koristiti u istraživanju. Također će se ukratko opisati struktura rada.
2. U **drugom** poglavlju opisat će se **teorijski aspekti korupcije**: pojam odnosno definicija te podjela korupcije, čimbenici koji izravno ili neizravno doprinose korupciji, ekonomski troškovi korupcije po vladine funkcije i institucije, društvo, okoliš itd., te metode mjerenja korupcije.
3. U **trećem** poglavlju, koje zajedno s drugim zaokružuje teorijski dio rada, dat će se **pregled rezultata dosadašnjih empirijskih istraživanja** odnosa poreznog sustava i korupcije.
4. **Četvrto** poglavlje činit će **empirijski dio** rada, u kojem će se testirati hipoteze o utjecaju složenosti poreznog sustava odnosno porezne strukture na korupciju u zemljama odabranog uzorka. Prvo će se definirati podaci i metodologija istraživanja, a zatim će se iznijeti rezultati statističke analize.
5. **Peto** poglavlje predstavlja **zaključak**, gdje će se rezimirati rezultati dobiveni u empirijskom dijelu rada, te će se donijeti sudovi na temelju sinteze teorijskog i empirijskog dijela rada.

Na kraju slijedi popis literature, popis tablica i slika, te sažetak na hrvatskom i engleskom jeziku.

Hipoteze koje će se ovim istraživanjem provjeravati su sljedeće:

**H1: Države sa složenijim poreznim sustavima korumpiranije su od onih s manje složenim sustavima.**

Logika ove poveznice tiče se problema fiskalne iluzije: naime, radi se o „prividu što ga stvara država tako da se porezi čine nižima, a socijalne koristi većima nego što stvarno jesu.“[1] Drugim riječima, što je porezni sustav složeniji i kompliciraniji, to je teže poreznim obveznicima procijeniti pravu „cijenu“ javnih dobara, odnosno koliko ih je financijski opteretilo plaćanje poreza iz kojih se ta javna dobra financiraju. Iz tog razloga bit će skloniji podržavati veću vladinu potrošnju, što će stvarati više prilika za korupciju (Liu i Feng 2015, str. 59). Primjerice, javni investicijski projekti često čine plodno tlo za korupciju, zbog diskrecije koja je dana visokim javnim dužnosnicima u pogledu odabira izvršitelja projekta, odnosno mogućnosti da isti dobiju određene „provizije“ od odabranih izvršitelja (Tanzi 1998, str. 12). Nadalje, pod utjecajem fiskalne iluzije građani će biti manje motivirani za nadzor vlade i njezinih nedoličnih činova (Liu i Feng 2015, str. 59). Također, ukoliko su porezni zakoni teško razumljivi i mogu se protumačiti na više načina, korupcija može postati značajan problem u poreznoj administraciji (Tanzi 1998, str. 11-12).

**H2: Države koje se više oslanjaju na indirektne poreze korumpiranije su od onih koje se više oslanjaju na direktne poreze.**

Kod direktnih poreza predmet oporezivanja jest dohodak ili imovina poreznog obveznika, što čini ovu vrstu poreza transparentnijom, te smanjuje vjerojatnost prevaljivanja poreza. Nasuprot tome, indirektni porezi „skriveni“ su u cijenama dobara i usluga, što poreznom obvezniku otežava procjenu svojeg financijskog doprinosa realizaciji javnih programa (Liu i Feng 2015, str. 59). Dakle, to opet produbljuje fiskalnu iluziju i rezultira većom potražnjom za javnim dobrima, što u konačnici vodi većoj korupciji, iz istih razloga koji su navedeni u elaboraciji hipoteze H1.

S druge strane, Tanzi i Davoodi (2000, str. 22) otkrili su da se zemlje koje su ranije uvele PDV kasnije suočavaju s nižim razinama korupcije. No u svakom slučaju, visokorazvijene zemlje sklonije su direktnim porezima, a zemlje u razvoju indirektnim (Nikolić 1999, str. 94).

[1] http://www.poslovni.hr/leksikon/fiskalna-iluzija-1250 [17.08.2016.]

### 1.3. Metode istraživanja

U ovome istraživanju koristit će se sljedeće znanstvene metode:

**Induktivna metoda**, kojom se, „na temelju pojedinačnih činjenica i saznanja, dolazi do uopćavanja i formiranja zakonitosti, odnosno spoznaje novih činjenica i novih zakonitosti.“ (Zelenika 2000, str. 323). **Deduktivna metoda**, kojom se „iz općih stavova izvode posebni, pojedinačni, iz općih postavki dolazi se do konkretnih pojedinačnih zaključaka, iz jedne ili više tvrdnji izvodi se neka nova tvrdnja koja proizlazi iz prethodnih tvrdnji.“ (Zelenika 2000, str. 325). **Metoda analize** je „postupak znanstvenog istraživanja i objašnjenja stvarnosti putem raščlanjivanja složenih misaonih tvorevina (pojmova, sudova i zaključaka) na njihove jednostavnije sastavne dijelove i elemente i izučavanje svakog dijela (i elementa) za sebe i u odnosu na druge dijelove, odnosno cjeline.“ (Zelenika 2000, str. 327) Podtipovi metode analize koji će se koristiti su **kvantitativna analiza**, **kvalitativna analiza** te **makroekonomska analiza**. **Metoda sinteze**, s druge strane, istražuje i objašnjava stvarnost putem „spajanja, sastavljanja jednostavnih misaonih tvorevina u složene i složenijih u još složenije, povezujući izdvojene elemente, pojave, procese i odnose u jedinstvenu cjelinu u kojoj su njezini dijelovi uzajamno povezani.“ (Zelenika 2000, str. 329-330). S obzirom na niz čimbenika koji, osim poreznog sustava, utječu na korupciju (npr. Tanzi 1998, str. 10-20), neizbježna će biti uporaba **metode apstrakcije**, budući da se pomoću nje „odvajaju nebitni a ističu bitni elementi i osobine određenog predmeta ili pojave istraživanja.“ (Zelenika 2000, str. 332)

U teorijskom dijelu rada, s obzirom na potrebu citiranja dosadašnjih spoznaja o problemu i predmetu istraživanja, koristit će se **metoda kompilacije**. Istovremeno, opisivanje logike uzročnih veza između promatranih varijabli predstavlja uporabu **metode deskripcije**. Također, budući da će uzorci promatranih varijabli obuhvaćati protekla vremenska razdoblja, može se govoriti o uporabi **povijesne metode**.

U empirijskom dijelu rada koristit će se **statistička metoda**. Ispitivanje uzročnih veza između elemenata poreznog sustava i korupcije vršit će se pomoću **linearne *cross-country* regresije**. Razlog tome je što korupcija mnogo više varira između država nego što se mijenja tijekom vremena, stoga panel analiza ne bi bila odgovarajući izbor za ovo istraživanje. Osim toga, složenost poreznog sustava općenito je stabilna varijabla tijekom dužih vremenskih razdoblja (Liu i Feng 2015, str. 60). Konačno, radi vizualnog prikaza povezanosti među varijablama koristit će se i **grafičko prikazivanje**.

### 1.4. Doprinos istraživanja

Rezultati dosadašnjih istraživanja upućuju na negativan utjecaj korupcije na prikupljene prihode od poreza u državi. Međutim, razumijevanje uzročnog odnosa tih dviju varijabli još uvijek nije potpuno, budući da o suprotnom uzročnom odnosu, utjecaju poreza na korupciju, nema dovoljno empirijskih podataka (Nawaz 2010, str. 4).

Doprinos ovoga istraživanja ogleda se u činjenici da je proučavanje utjecaja poreznog sustava na korupciju relativna novost u literaturi. Naime, kao što je spomenuto, opsežnija istraživanja na tu temu provode se tek unatrag nekoliko godina. Osim toga, posebnost ovoga istraživanja jest što će se promatrati isključivo zemlje članice Europske Unije. Budući da istraživanje Awasthija i Bayraktara (2014, str. 35) sugerira slabiju vezu složenosti poreznog sustava i korupcije u bogatijim zemljama, bit će korisno provjeriti koliko je ta veza jaka, i postoji li uopće, na razini Europske Unije, koja ima i razvijenije i manje razvijene članice. Isto vrijedi i za vezu porezne strukture i korupcije, odnosno promatrat će se razvijene europske zemlje, te zemlje koje nastoje postati takvima.

# 2. POJAM, ČIMBENICI I TROŠKOVI KORUPCIJE

## 2.1. Definicija, podjela i pojavni oblici korupcije

Definiranje korupcije nije jednostavno zbog raznolikosti njezinih pojavnih oblika te prikrivenosti od pogleda javnosti. Ipak, jedna od najčešćih i najsažetijih definicija, koju koriste i Svjetska banka te *Transparency International*, glasi da je korupcija „**zlouporaba javnog položaja radi privatne koristi**“ (IMF 2016, str. 3). Khan (1996, str. 12, prema Amundsen 1999, str. 2) definira korupciju kao „ponašanje koje odudara od formalnih pravila ponašanja koja se tiču djelovanja na položaju javne vlasti, radi privatnih motiva poput bogatstva, moći ili statusa.“

Korupcija, dakle, predstavlja narušen odnos države i društva, gdje državu predstavljaju službenici, birokrati ili političari, koji su ovlašteni dodjeljivati prava nad (oskudnim) javnim resursima u njezino ime. Privatna korist, spomenuta u definiciji, znači da je službenikova odluka donesena iz razloga koji nisu navedeni kao relevantni od strane pravnog ili administrativnog okvira kojeg službenik provodi. Dotični, primjerice, primi novac ili neki drugi oblik nagrade kako bi zloupotrijebio svoje ovlasti u svrhu vraćanja usluge (Amundsen 1999, str. 2; IMF 2016, str. 3-4).

Premda se gore navedene definicije tiču javnih službenika, korupcija je prisutna i u privatnom sektoru, primjerice kad se privatna poduzeća međusobno podmićuju, varaju ili provode mafijaške metode, ili kad u poduzećima djeluju nelojalni zaposlenici. Ovakav oblik korupcije može imati negativne posljedice po politički sustav, budući da ruši javni moral (Amundsen 1999, str. 3).

Nijedno društvo nije imuno na pojedinačne, izolirane slučajeve korupcije, no u nekim situacijama korupcija više nije samo kršenje normi, već postaje obrazac ponašanja toliko raširen i ukorijenjen da sam postaje norma. U takvim uvjetima sposobnost države da izvršava svoje osnovne funkcije, poput prikupljanja prihoda, pružanja javnih dobara i usluga, reguliranja tržišta i slično, postaje toliko narušena da to značajno utječe na ekonomske performanse (IMF 2016, str. 3-4).

Neke od češćih podjela korupcije su: na **političku** (eng. *grand*) i **birokratsku** (eng. *petty*), **privatnu** i **kolektivnu**, te na **redistributivnu** („odozdo“) i **ekstraktivnu** („odozgo“) (Amundsen 1999, str. 5).

**Politička korupcija** odvija se na visokim razinama političkog sustava, to jest kad su političari i državni dužnosnici, koji su ovlašteni donositi i provoditi zakone u ime naroda, sami korumpirani. Drugim riječima, kad se donositelji političkih odluka služe ovlastima koje su im povjerene kako bi zadržali svoju moć, status ili bogatstvo. Politička korupcija nije samo otklon od pisanih pravnih normi ili kodeksa etike, već njihova sustavna zlouporaba, izbjegavanje ili prilagođavanje interesima vladajućih. Osnovni problem je, dakle, manjak odgovornosti vladajućih. Politička korupcija jedna je od osnovnih značajki autoritarnih režima, no pojavljuje se i u demokratskim sustavima (Amundsen 1999, str. 3-4).

**Birokratska** ili **„sitna" korupcija** odvija se u svakodnevici, u izravnom kontaktu između birokrata i javnosti. Još se naziva i „korupcija iz potrebe," jer ju provode službenici nižeg ili srednjeg ranga, koji su često vrlo slabo plaćeni. Birokratska korupcija najviše šteti najsiromašnijim slojevima društva, koji se redovito susreću sa zahtjevima za mitom prilikom potraživanja zdravstvenih, obrazovnih, sigurnosnih ili drugih usluga, pri ishodovanju dozvola, plaćanju poreza i tako dalje.[2]

**Privatna** ili **pojedinačna korupcija** provodi se u korist pojedinca i njegovih bližnjih, koji će vrlo malo ili ništa od te koristi podijeliti s drugima. Ipak, s obzirom na nemoralnu i ilegalnu narav korupcije, potreban je neki oblik dosluha i povjerljivosti, zbog čega se korupcija i naziva „*tajnom* društvenom razmjenom." S druge strane, **kolektivna korupcija** namjerno je izvlačenje resursa u korist veće skupine ljudi, poput političkih stranaka, administrativnih biroa ili nacionalnih vlada. Korupcija je fenomen vrlo sklon „kolektivizaciji," jer je u praksi jednostavnije šutjeti i postupno početi sudjelovati, nego postati „zviždačem." Tako se zavjera nekoliko pojedinaca s vremenom proširi na kolege, partnere, pomoćnike, nadređene itd. Veće mreže i klanovi zatim mogu evoluirati u institucionaliziranu mrežu korupcije, ukoliko se na vrijeme ne dovede pod kontrolu (Amundsen 1999, str. 4-5).

Konačno, kad se vrši koruptivno djelo, za očekivati je da će i država (tj. njezin namještenik) i društvo (pojedinačni građanin, klijent ili poduzetnik) ostvariti neku privatnu i neposrednu korist. Međutim, iznos koristi za obje strane rijetko će biti jednak: ukupno gledajući, jedna od strana imat će više koristi od takve razmjene. Ukoliko više koristi ima država, u pitanju je **ekstraktivna korupcija** ili **korupcija „odozgo."** Suprotno tome, ako više koristi ima društvo, radi se o **redistributivnoj** ili **korupciji „odozdo."** Kod korupcije

[2] http://www.u4.no/glossary/petty-corruption-see-bureacratic-corruption/ [16.08.2016.]

„odozgo“ vladajuća elita izvlači značajne, opipljive resurse iz naroda odnosno društva (npr. novac, bogatstvo, fiskalne privilegije), dok društvo zauzvrat dobiva tek simbolične, neopipljive koristi. Na primjer, kada državne sigurnosne službe i paravojne postrojbe iznuđuju novac od pojedinaca i skupina kako bi ih „zaštitila“ od daljnjeg uznemiravanja, žrtva iznude ne dobiva ništa osim negativne slobode, labavog obećanja o nekažnjavanju (Amundsen 1999, str. 13-14). Ovakve prakse u brojnim su slučajevima rezultirale nastankom vrlo imućnih vladajućih elita usred siromaštva i recesije. S druge strane, korupcija „odozdo“ događa se u slabim režimima, gdje korumpirani državni službenici nisu u stanju odoljeti pritiscima od strane privatnih kompanija ili drugih interesnih skupina, zbog čega naposljetku dolazi do nepovezanosti države i njezinih vlastitih politika, te iscrpljenja nacionalnih resursa (Amundsen 1999, str. 5-6).

Neki od najčešćih pojavnih oblika korupcije su mito, iznuda, pronevjera, prijevara te favoritizam odnosno kronizam, a objašnjeni su u nastavku.

**Mito** može biti fiksan iznos, određeni postotak ugovora ili druga usluga u novcu plaćena državnom službeniku koji je ovlašten sklapati ugovore u ime države ili na drugačiji način distribuirati beneficije poduzećima, pojedincima, poduzetnicima i klijentima. Podmićivanje se vrši radi lakšeg ili bržeg prolaska predmeta kroz birokraciju ili izbjegavanja kakve obveze, a mnoge korporacije podmićuju i radi kupovine političkih usluga, zaštićenih tržišta, monopola ili uvoznih/izvoznih licenci, izbjegavanja poreznih obveza ili odredbi o zaštiti okoliša itd. (Amundsen 1999, str. 11). Mito može inicirati osoba koja ga nudi ili osoba koja ga prima, a osim novčane koristi, primatelj mita može steći i manje opipljive koristi, poput primjerice insajderskih informacija ili zaposlenja (Vargas-Hernández 2009, str. 3-4).

**Iznuda** je u principu oblik prinudne inicijative, poput prijetnje nasiljem ili puštanjem štetnih informacija, u svrhu prisile na suradnju. U kontekstu birokratske korupcije, iznuda se odnosi na naplaćivanje većih cijena ili naknada za dozvole, licence i sl., od strane državnih službenika koji ih izdaju (Vargas-Hernández 2009, str. 5). U kontekstu političke korupcije, iznuda se događa kad sama država, odnosno njezini agenti, iznuđuju novac od pojedinaca i skupina kako bi ih „zaštitila,“ kao što je upravo i spomenuto u definiciji ekstraktivne korupcije.

**Pronevjera** je krađa javnih resursa od strane državnih službenika. Državni službenik uzima od javne institucije za koju radi i čijom je imovinom ovlašten upravljati u ime države i javnosti. Međutim, i nelojalni zaposlenici privatnih poduzeća mogu pronevjeriti razne vrste

sredstava svojeg poslodavca (Amundsen 1999, str. 11-12), od krađe sitnog inventara do preusmjeravanja novca (eng. *siphoning*), zlouporabe platne liste poduzeća, lažiranja evidencije prekovremenih sati itd.[3] Na razini političke korupcije, jedan od oblika pronevjere jest korištenje političke moći radi razvijanja i širenja vlastitih poslovnih interesa, na primjer nacionalizacijom stranih poduzeća i njihovom redistribucijom članovima vladajuće obitelji. Također, privatizacija je često bila dobar izgovor za davanje državnih poduzeća u ruke prijateljima ili obiteljima vladajućih za simbolične iznose (Amundsen 1999, str. 12).

**Prijevara** je zločin kojega karakterizira neki oblik obmane, te u širem pravnom i kolokvijalnom smislu obuhvaća i mito i pronevjeru. Primjeri prijevare su kad su državne agencije i državni dužnosnici angažirani na crnom tržištu, te kada podupiru mreže krivotvoritelja, trgovinu ilegalnim dobrima, krijumčarenje i sl. Ukratko, prijevarama se služe vladajuće skupine kako bi si osigurale veću korist (Amundsen 1999, str. 12-13).

**Favoritizam** ili **kronizam** (eng. *cronyism*) je dodjela položaja ili beneficija obitelji i prijateljima, bez obzira na zasluge. To je mehanizam zlouporabe ovlasti koji uključuje „privatizaciju" i vrlo pristranu distribuciju državnih resursa, neovisno o načinu na koji su ti resursi akumulirani. Primjeri favoritizma su omogućavanje „odabranima" da jeftino kupe privatiziranu javnu imovinu, da podignu subvencionirane ili od države garantirane kredite, da izvršavaju javne radove, da predstavljaju korporativne interese u raznim savjetima i odborima itd. Preko takvih mehanizama mnogi političari i birokrati prešli su iz javnog položaja u privatni sektor, kako bi javni utjecaj pretvarali u privatno bogatstvo.

Kad ovlaštena osoba favorizira članove obitelji, radi se o nepotizmu (Amundsen 1999, str. 14-15), no favorizirati se mogu i stranački kolege, pripadnici iste etničke, religijske ili neke druge skupine i sl. U takvim uvjetima građani su primorani slijediti neformalna pravila i korumpirane prakse kako bi si osigurali pristup javnim dobrima, uslugama i beneficijama, jer ih karakterizira nepovjerenje u transparentnost i efikasnost državnih institucija (Vargas-Hernández 2009, str. 6).

[3] https://geoffreygnathanlaw.com/6-examples-of-embezzlement/ [16.08.2016.]

## 2.2. Čimbenici korupcije

### 2.2.1. Izravni čimbenici

Korupcija se općenito povezuje s aktivnostima države te njezinim monopolskim i diskrecijskim ovlastima. Prema Beckeru, [4] uzrok korupcije posvuda je isti: „krupna" administracija koja ima moć dijeliti mnogo dobara različitim skupinama. Međutim, civilizirano društvo ne može funkcionirati bez države i njezine administracije, koja u suvremenim društvima mora izvršavati nekolicinu uloga. Također, neke od najmanje korumpiranih država na svijetu, poput Kanade, Finske, Nizozemske ili Švedske, istovremeno imaju i velik javni sektor u smislu udjela prihoda od poreza ili javne potrošnje u BDP-u. Stoga problem korupcije nije moguće riješiti jednostavnim smanjenjem javnog sektora, već je daleko važniji način na koji država djeluje i izvršava svoje funkcije. Specifični aspekti državnih aktivnosti predstavljaju plodno tlo za korupciju, o čemu se raspravlja u nastavku (Tanzi 1998, str. 10-15).

**Regulacije i dozvole**. Jedna od uloga države jest dodjeljivanje dokumenata, dozvola, licenci i autorizacija raznih vrsta, koje su potrebne za bavljenje, ili nastavak bavljenja nekolicinom aktivnosti, kao što su primjerice otvaranje dućana, posuđivanje novca, ulaganje, vožnja automobila, gradnja kuće, ishodovanje putovnice itd. Postojanje ovih regulacija pruža svojevrsnu monopolsku moć službenicima koji ih izdaju: oni ih mogu odbiti izdati ili jednostavno odugovlačiti s izdavanjem mjesecima. Prema tome, oni imaju moć zatražiti mito od onih kojima su ti dokumenti potrebni. Također, velika količina vremena koje građani moraju utrošiti u kontaktu s javnim službenicima poradi pribavljanja dokumenata, može se smanjiti davanjem mita. Studije iz brojnih država, a najviše iz onih u razvoju ili tranziciji, ukazuju na to da menadžeri poduzeća, pogotovo malih, provode velik udio svog vremena u poslovima s birokracijom, stoga je jasno da bi im bilo u interesu uštedjeti si to vrijeme.

**Porezi**. Ukoliko je porezni sustav temeljen na jasnim zakonima i ne zahtijeva čest kontakt poreznog obveznika i inspektora, pojava korupcije mnogo je rjeđa. S druge strane, čimbenici koji korupciju mogu učiniti značajnim problemom u poreznoj i carinskoj administraciji su sljedeći:

[4] http://www.bloomberg.com/news/articles/1995-12-10/if-you-want-to-cut-corruption-cut-government [16.08.2016.]

1. Zakone je teško razumjeti i mogu se protumačiti na više načina, zbog čega je obveznicima u tome potrebna pomoć.
2. Plaćanje poreza zahtijeva čest kontakt poreznih obveznika i administratora.
3. Plaće poreznih administratora su niske.
4. Korumpiranost od strane poreznih administratora ignorira se, teško se otkriva ili se tek blago kažnjava jednom kad se otkrije.
5. Administrativne procedure nisu transparentne i ne nadziru se pozorno unutar porezne ili carinske administracije.
6. Porezni administratori imaju diskreciju nad važnim odlukama, primjerice onima koje se tiču odobrenja poreznih olakšica, određivanja poreznih obveza, odabir poslovnih subjekata za inspekciju, itd.
7. Općenito, kad kontrola države (principala) nad agentima čija je dužnost obavljanje njezinih funkcija slaba.

**Pružanje dobara i usluga ispod tržišne cijene**. U većini država, ova dobra i usluge tiču se međunarodne razmjene, kredita, struje, vode, javnog stanovanja, nekih racioniranih dobara,[5] pristupa obrazovnim i zdravstvenim ustanovama, javnim zemljištima itd. U ovu skupinu spadaju i invalidske mirovine, jer su pojedinci koji ih primaju uplatili manje u doprinosima od iznosa mirovine koju počnu primati jednom kad im se odobri invalidski status. U svakom slučaju, zbog ograničene ponude dobra ili usluge, racioniranje ili čekanje u redu postaje neizbježno, jer se stvara višak potražnje koja se mora prilagoditi ponudi. Budući da državni službenici često odlučuju o tome tko će dobiti pristup određenom dobru ili usluzi, njihovi potencijalni korisnici bit će voljni dati mito kako bi došli do istog.

**Slika 1.** prikazuje ovaj fenomen. Na horizontalnoj osi prikazana je količina ponude odnosno potražnje, a na vertikalnoj osi cijena. Krivulja DD' predstavlja potražnju, a krivulja A iznos ponude javnog dobra. Slijedom toga, P predstavlja ravnotežnu cijenu. Ukoliko država postavi cijenu na P', iznos koji je manji od P, dolazi do viška potražnje (AA') koji se ne može zadovoljiti trenutnom razinom ponude, zbog čega dolazi do racioniranja javnog dobra, te posljedično ponude ili zahtijevanja mita.

[5] **Racioniranje** podrazumijeva državnu politiku planiranog ograničenja alokacije oskudnih resursa i potrošačkih dobara, obično tijekom rata, prirodne katastrofe ili kakve druge izvanredne situacije. Cilj ove politike jest spriječiti nestašicu, odnosno osigurati da stanovništvo dobije potrebnu količinu nužnog dobra. Izvor: http://www.investopedia.com/terms/r/rationing.asp [04.09.2016.]

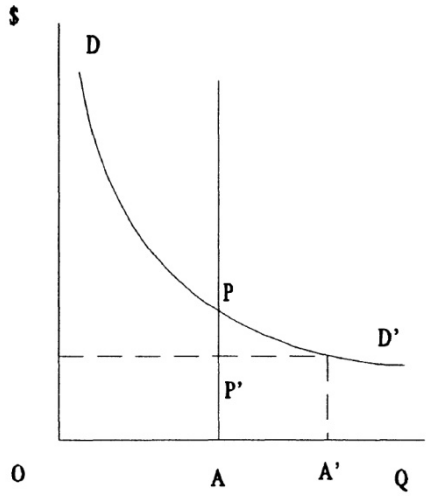


**Slika 1: Ponuda, potražnja i cijena racioniranog dobra**

Izvor: Tanzi (1998, str. 14, Figure 1).

**Državna potrošnja**. Korupcija utječe na državnu potrošnju u nekoliko područja. **Javna nabava**, koja predstavlja vrlo važnu državnu i ekonomsku aktivnost vrijednu 4,2 trilijuna eura u zemljama OECD-a, najpodložnija je korupciji: 57% ukupno plaćenog mita odnosilo se upravo na javnu nabavu. Uzrok tome su financijski interesi, volumen transakcija te bliska interakcija javnog i privatnog sektora pri dodjeli javnih ugovora (OECD 2016, str. 4-8). Neke su države razvile složene i skupe procedure radi smanjenja korupcije, no to je došlo s troškom u vidu veće cijene nabave određenih dobara. Nadalje, **investicijski projekti** podložni su korupciji na visokim razinama zbog diskrecije koju visoki javni dužnosnici imaju pri odlučivanju o istima. Ponekad su čak javni projekti izvršavani s isključivim ciljem pružanja koristi pojedincima ili političkim grupacijama, kako bi dobili „provizije“ od odabranih izvršitelja radova. Takve situacije smanjuju produktivnost potrošnje i rezultiraju projektima kakvi ne bi bili opravdani prema uobičajenim kriterijima vrednovanja investicijskih projekata, poput primjerice *cost-benefit* analize. Također, u brojnim državama uobičajeni su **vanbudžetski fondovi** (eng. *extra-budgetary funds*). Taj pojam podrazumijeva javne resurse i državne transakcije koje nisu uključene u godišnji proračun ili nisu podložne istim standardima izvještavanja, regulacije ili revizije kao ostale stavke javnih financija. U pravilu uključuju mirovinske fondove ili fondove socijalne skrbi, fondove u vlasništvu državnih poduzeća, ostale diskrecijske ili tajne fondove itd., a može uključivati i novčane primitke od međunarodne pomoći, prodaje prirodnih resursa i sl. U prosjeku se u tranzicijskim zemljama i

zemljama u razvoju na vanbudžetske fondove odnosi oko 40 posto državne potrošnje.[6] Nedostatak transparentnosti u ovome području može rezultirati usmjeravanjem novca na druge račune ili u privatne džepove. Primjerice, zbog oscilacije cijena dobara u kratkom vremenu, može biti teško odrediti po kojoj je cijeni transakcija obavljena. Eventualna razlika između stvarne i objavljene cijene može završiti na stranom računu.

**Financiranje političkih stranaka**. U demokracijama je velik problem financiranje aktivnosti političkih stranaka, uključujući predizborne kampanje. Kad javni novac nije dostupan, stvara se enorman pritisak za prikupljanjem sredstava.

Također, neke od ostalih diskrecijskih odluka koje su podložne korupciji su:

1. odobravanje **poreznih olakšica** za poreze na dohodak, dodanu vrijednost ili međunarodnu trgovinu, koje mogu biti vrijedne milijune dolara u sadašnjoj vrijednosti umanjenih budućih obveza za porezne obveznike,
2. odluke o **namjeni privatnih zemljišta** (**prostorno planiranje**), koje određuju hoće li se zemljište koristiti isključivo za poljoprivredu (i time imati malu tržišnu vrijednost) ili za visokogradnju (i postati vrlo skupo),
3. odluke o **namjeni zemljišta u državnom vlasništvu**, primjerice za sječu šuma ili rudarstvo. U brojnim državama zabilježeni su slučajevi korupcije vezani za izdavanje dozvola za sječu državnih šuma ili iskorištavanje ruda,
4. odobravanje **stranih investicija**, često povezanih s domaćim interesima, često pruža određenu monopolsku moć povlaštenim ulagačima,
5. odluke o **prodaji državne imovine**,
6. odluke o **privatizaciji državnih poduzeća** te o uvjetima iste, poput stupnja regulacije industrije,
7. odluke koje **pružaju monopolsku moć** određenim izvoznim, uvoznim ili domaćim aktivnostima.

Odluke opisane iznad mogu biti od velike vrijednosti pojedincima ili poduzećima. Stoga je razumljivo da će neki od njih pokušati steći povoljan ishod, bilo nuđenjem mita, bilo iskorištavanjem dobrih odnosa s javnim službenicima. Ukoliko su istima plaće niske, njihova „cijena“ mogla bi biti bitno manja od potencijalne koristi ponuditelju.

[6] http://www.internationalbudget.org/wp-content/uploads/Looking-Beyond-the-Budget-1-Extrabudgetary-Funds.pdf [17.08.2016.]

2.2.2. Neizravni čimbenici

Osim čimbenika koji izravno doprinose korupciji, postoje i oni koji to čine na neizravan način, a navode se u nastavku (Tanzi 1998, str. 16-20).

**Kvaliteta birokracije** znatno varira među državama. U nekima posao u državnoj službi donosi prestiž i status, u drugima ne u tolikoj mjeri. Tradicija i njezin utjecaj na ponos kojeg pojedincu stvara državni posao objašnjava zašto su, *ceteris paribus*, neki birokratski sustavi mnogo efikasniji i manje podložni korupciji od drugih. Također, cilj zapošljavanja u javnom sektoru trebalo bi povećanje efikasnosti administracije, a ne smanjenje nezaposlenosti. Rauch i Evans (1997, prema Tanzi 1998, str. 16) su na uzorku od 35 zemalja u razvoju otkrili da što su manje zapošljavanja i promaknuća zasnovana na zaslugama, veći je opseg korupcije.

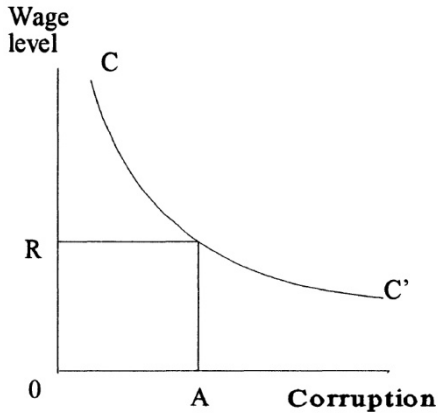


**Slika 2: Korupcija i visina plaće u javnom sektoru**
Izvor: Tanzi (1998, str. 17, Figure 2).

**Visina plaća u javnom sektoru**. Sklonost korupciji rezultat je pohlepe, ali i potrebe. Na **Slici 2.**, krivulja CC' prikazuje *trade-off* između korupcije i visine plaće: što je veća plaća, manje je korupcije. Ako je minimalna plaća potrebna za dostojanstven život R, tada se može pretpostaviti da je korupcija do iznosa A iz pohlepe, a iznad tog iznosa – iz potrebe. S obzirom da krivulja CC' ne siječe horizontalnu os, nameće se zaključak da će, bez obzira na visinu plaće, neki službenici biti korumpirani, možebitno zbog svoje vlastite psihološke ili moralne naravi, ili pojedinih primamljivih ponuda mita. Rijckeghem i Weder (1997, prema Tanzi 1998, str. 17) su empirijski potvrdili ovaj međuodnos, navodeći između ostalog i da iako bi povećanje plaća smanjilo korupciju, bilo bi potrebno mnogo veće povećanje kako bi se

ona dovela na minimalne razine (zato krivulja eksponencijalno opada). Stoga se protiv korupcije nije isplativo boriti isključivo u području plaća, već je potreban sveobuhvatniji pristup. Visina plaća također je važna i radi vrbovanja sposobnih, produktivnih i poštenih pojedinaca za rad u državnim službama.

Bez obzira na navedeno, u ekonomskoj literaturi se teoretizira da premda visoke plaće mogu smanjiti broj koruptivnih djela, one mogu rezultirati zahtjevima za većim pojedinačnim iznosima mita od strane onih službenika koji nastavljaju biti korumpirani. Razlog tome jest što visoke plaće povećavaju oportunitetni trošak otkaza, ali ne eliminiraju pohlepu spomenutih službenika. Prema tome, ukupan iznos novca plaćenog u svrhu podmićivanja ne mora se nužno smanjiti povećanjem plaća.

**Sustav kazni**. Prema Beckerovoj (1968, prema Tanzi 1998, str. 18) klasičnoj analizi prevencije zločina, uz danu vjerojatnost da će počinitelj zločina biti uhvaćen, izrečena kazna bitno utječe na vjerojatnost počinjenja kriminalnog djela.

U stvarnosti relativno malo ljudi biva kažnjeno zbog korupcije, usprkos raširenosti fenomena. Također, postoji velik jaz između kazni propisanih zakonom i kazni koje se izriču: u pravilu su efektivne kazne blaže od propisanih. Administrativne procedure koje se moraju slijediti kako bi se pojedinac kaznio spore su i nezgrapne, a često i pravne ili političke zapreke sprječavaju potpuno ili brzo izricanje kazni. Potrebno je slijediti redoviti zakonski postupak i osigurati neosporive dokaze, a potencijalni optužitelji često su neodlučni oko istupanja i utroška vremena i truda na proces. Također, troškovi optužiteljima, u smislu izgubljenog društvenog kapitala, značajni su: čak i u zemljama koje ne slove kao korumpirane, tzv. „zviždačima“ nije lako. Konačno, i suci mogu biti pristrani ili korumpirani, pa ih optuženici mogu kupiti ili sabotirati proces. Svi navedeni čimbenici dovode do tolerancije prema manjim koruptivnim djelima, što s vremenom potiče i veća takva djela.

**Institucionalne kontrole**. Drugi važan sastojak Beckerove analize jest vjerojatnost otkrivanja počinitelja prijestupa, što vodi ulozi institucionalnih kontrola. Postojanje takvih kontrola u velikoj je mjeri ogledalo stava političkog tijela prema problemu: u pravilu se najefektivnije kontrole nalaze unutar institucija. Pošteni i učinkoviti nadzornici, dobre revizorske službe i jasna pravila etičnog ponašanja trebali bi obeshrabriti ili otkriti koruptivne aktivnosti. Dobre i transparentne procedure trebale bi olakšati institucijama provođenje kontrola, a nadzornicima omogućiti praćenje svojih podređenih.

U mnogim državama osnivala su se povjerenstva i službe za borbu protiv korupcije, čiji je zadatak bio razmatrati prijave takvih slučajeva. Ovakva služba morala bi biti neovisna od političkog establišmenta, te imati na raspolaganju dovoljno resursa, kadar od najvišeg integriteta, te moć izricanja kazni. Nažalost, u nekim državama ovakva služba povjerljivo izvještava predsjednika države ili premijera, umjesto zakonodavno tijelo, što umanjuje učinkovitost i politizira proces. U drugim državama ovakve službe nemaju ovlasti izricati kazne, a istovremeno slučajeve ne preuzimaju ni druge institucije.

**Transparentnost pravilnika, zakona i procesa**. Nedostatak transparentnosti u ovome području stvara plodno tlo za korupciju. Pravilnici budu zbunjujući, mijenjaju se bez adekvatne najave, dokumenti koji ih specificiraju nisu javno dostupni, zakoni su pisani na način da ih mogu protumačiti samo obučeni pravnici ili su konceptualno i lingvistički dvosmisleni tako da je teško odrediti na koji se način došlo do određene odluke.

**Primjer vodstva**. Kad politički lideri ne pružaju dobar primjer, bilo da se sami bave koruptivnim djelima ili ih tek toleriraju svojoj rodbini, prijateljima ili političkim partnerima, teško je očekivati da će se javni službenici ponašati drugačije. Isto vrijedi i za pojedinačne institucije i njihova vodstva. Nužan uvjet za djelovanje slobodno od korupcije jest adekvatan primjer poštenja kojeg pružaju vodeći.

## 2.3. Ekonomski troškovi korupcije

Troškovi korupcije značajni su: premda ih je teško točno izmjeriti, predodžbu o veličini ovoga fenomena moguće je steći uvidom u iznose mita plaćenog u razvijenim zemljama i zemljama u razvoju. Nedavno je procijenjeno da trošak isključivo mita godišnje iznosi oko 1,5 do 2 trilijuna američkih dolara, ili oko 2% svjetskog BDP-a. Budući da mito predstavlja tek jedan od aspekata korupcije, za očekivati je da su ekonomski i socijalni troškovi korupcije još i veći (IMF 2016, str. 5). U nastavku slijede neka od osnovnih područja u kojima korupcija stvara troškove (IMF 2016, str. 5-15).

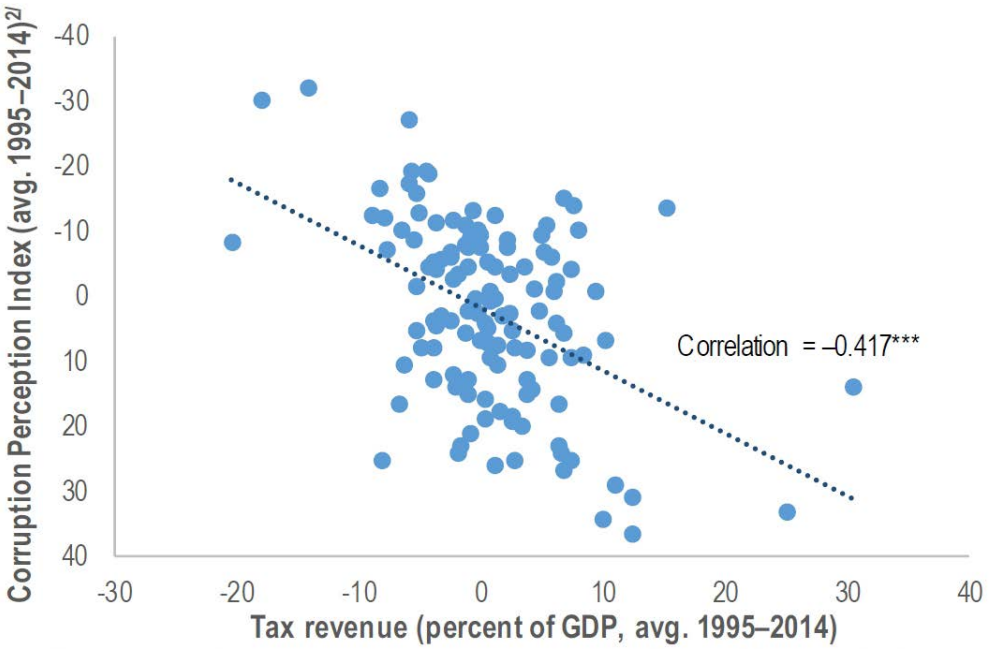


**Slika 3: Prihodi od poreza i korupcija**

Izvor: IMF (2016, str. 7, Figure 2a).

**Porezni sustav**. Prvo, korupcija šteti kulturi plaćanja poreza, čime dolazi do učestalijih pojava utaje. Dakle, umanjuje se sposobnost države da prikuplja poreze, što u konačnici rezultira manjim javnim prihodima. Negativan odnos korupcije i prihoda od poreza potvrđen je empirijski (npr. Aghion *et al.* 2016), i prikazan je na **Slici 3**. Na horizontalnoj osi prikazane su devijacije od prosječnog udjela prihoda od poreza u BDP-u tijekom razdoblja od 1995. do 2014. godine, a na vertikalnoj osi devijacije od indeksa percepcije korupcije (CPI) u istom razdoblju. O ovome pokazatelju bit će više riječi u nastavku, no ono što je za sada bitno jest da veći iznos varijable CPI znači manji nivo korupcije u javnom sektoru. Prema tome, razvidno je da se u manje korumpiranim zemljama prikupljaju veći iznosi poreza.

Drugo, korupcija destimulira plaćanje poreza: naime, kad javnost smatra da se porezne olakšice stječu davanjem mita, postaje mnogo manje voljna pridržavati se poreznih propisa, budući da ih smatra nepravednima. Utaja poreza znatno doprinosi nejednakosti i doživljaju nepravde, podrivajući povjerenje građana u vlastite vlade. Također, nepovjerenje prema administraciji odvraća poduzetnike od započinjanja novih poslova, ili ih potiče na prelazak u sivu ekonomiju, što u svakom slučaju još više erodira porezne osnovice (Dreher i Herzfeld 2005, str. 7). Konačno, korupcija podriva programe potrošnje, što se u prvom redu manifestira troškovnom inflacijom i iskrivljenom alokacijom resursa, kao rezultat loših kontrola troškova, vanbudžetskih transakcija, nedostatka nadzora i tako dalje.

**Monetarni sustav**. Kako korupcija podriva sposobnost države da prikuplja poreze, tako se država sve više oslanja na financiranje putem emisijske dobiti (eng. *seigniorage*). To vodi fiskalnoj dominaciji, odnosno ugrožavanju neovisnosti i kredibiliteta središnje banke po pitanju provođenja monetarne politike. Kao rezultat toga, inflacija poprima veće vrijednosti u korumpiranijim državama.[7]

**Financijski sektor**. Prvo, korupcija koči financijski razvoj i uključivost, budući da u korumpiranijim državama javnost polaže manje depozita, i manje se kredita odobrava privatnom sektoru. Drugo, korumpirane prakse odobravanja kredita, slab nadzor nad bankarskim sustavom te regulatorna popustljivost ugrožavaju stabilnost financijskog sustava. Rastući udio nenaplativih zajmova umanjuje mogućnost banaka da dalje posuđuju, što se značajno odražava na rast i donosi fiskalne rizike po vladin budžet. Također, korupcija šteti kulturi plaćanja i povećava nepovjerenje tržišta, što umanjuje pristup međunarodnim kreditnim tržištima odnosno povećava troškove kreditiranja uslijed većeg rizika bankrota.

**Investicije**. Korupcija povećava troškove i smanjuje kvalitetu javnih investicija, utječući na njihovu selekciju putem mita, rentijerstva ili kronizma. Neadekvatni procesi nabave i održavanje rezultiraju lošim investicijskim ishodima i štete produktivnosti postojeće infrastrukture. Zbog navedenog u korumpiranijim državama manje je raspoložive i kvalitetne infrastrukture pri danoj razini javnog kapitala. Što se tiče privatnih investicija, mito koje je u korumpiranom sustavu potrebno platiti kako bi se osigurale sve dozvole u praksi djeluje kao porez na investiciju. Najštetnije djeluje neizvjesnost: kad investitor ne zna hoće li moći

[7] U situaciji **fiskalne dominacije**, fiskalni autoritet neovisno definira budžete i najavljuje buduće deficite odnosno suficite, čime određuje iznos prihoda koji treba prikupiti prodajom obveznica i emisijskom dobiti. Ukoliko potražnja za državnim obveznicama nije dovoljna za tu svrhu, monetarni autoritet primoran je ostatak potrebnih prihoda namaknuti stvaranjem novca, zbog čega je potrebno tolerirati dodatnu inflaciju (Sargent i Wallace 1981, str. 2).

ishoditi dozvolu plaćanjem mita i koliko će za to morati platiti. Zbog toga korupcija dokazano negativno utječe na strane izravne investicije, važan pokretač rasta. Ipak, kad postoji određena sigurnost po pitanju korupcije, kad se „zna kamo treba otići i koliko platiti," negativan utjecaj manje je izražen (Tanzi 1998, str. 22).

**Produktivnost i reforme**. Korupcija, prema rezultatima niza studija,[8] preusmjerava alokaciju resursa iz produktivnih u rentijerske aktivnosti, što može rezultirati ulaznim barijerama, manjkom inovacija, niskom produktivnošću poduzeća i naposljetku njihovim napuštanjem tržišta zbog većih troškova poslovanja uzrokovanih korupcijom.

**Ljudski kapital**. Javna potrošnja na obrazovanje i zdravstvo niža je u korumpiranijim sustavima jer je u takvim uvjetima administracijama lakše prikupljati mito na drugim javnim troškovima. Obrazovanje je, primjerice, posebno neprivlačna meta za rentijere, dobrim dijelom jer pružanje istog ne zahtijeva visokotehnološke *input*-e kakve pružaju oligopolski dobavljači (Mauro 1998, str. 277-278). Nadalje, mladi ljudi manje su motivirani ulagati u svoje obrazovanje ako im uspjeh u karijeri više ovisi o tome koga znaju, nego koliko znaju. Također, sustavna korupcija potiče emigraciju, pogotovo obrazovanijih ljudi, što državu lišava talenta i šteti dugoročnom rastu.

**Obrazovanje i zdravlje**. Smrtnost djece u korumpiranim zemljama viša je za oko trećinu u odnosu na manje korumpirane zemlje; udio novorođenčadi s niskom tjelesnom težinom dvostruko je veći, a postoci maloljetnika koji su se ispisali iz škole pet puta je veći. Sve navedeno je rezultat manje učinkovite javne potrošnje na socijalni sustav u korumpiranim zemljama.

**Socijalni sustav**. Osim što korupcija iskrivljava alokaciju resursa u zdravstvenom i obrazovnom sustavu, socijalni je sektor često pogođen apsentizmom neophodnih zaposlenika: apsentizam je rezultat korumpirane kulture rada koja tolerira slabe radne učinke. Nadalje, korištenje vladinih programa radi odobravanja beneficija već ionako dobrostojećim skupinama populacije ili preusmjeravanje novca iz programa za borbu protiv siromaštva umanjuje utjecaj socijalnih programa na distribuciju dohotka i siromaštvo.

**Okoliš**. Korumpiranije države istodobno su i zagađenije,[9] što se može objasniti slabijom regulativom zaštite okoliša, koja se ujedno i slabije provodi. Također, u

[8] Npr. Baumol (1990); Murphy, Schleifer i Vishny (1991); Dal Bó i Rossi (2007); sve prema IMF (2016, str. 11).
[9] Prema *per capita* emisijama $SO_2$ i $CO_2$ (Cole 2007, prema IMF 2016, str. 13).

korumpiranijim sustavima mito se koristi pri ishodovanju dozvola potrebnih za ekstrakciju prirodnih resursa, zbog čega dolazi i do njihovog iscrpljenja.

**Politička stabilnost.** Korupcija ne utječe samo na izvršavanje državne moći, već i na primjenu zakona, propisa i regulacija, a u ekstremnim slučajevima ih i oblikuje. To u osnovi potkopava povjerenje građana u nepristranost vlade i dovodi do nesloge i razdora u društvu, pogotovo kad vlada nagrađuje svoje pristaše iskorištavanjem drugih. Bez povjerenja u vladavinu prava, raširena korupcija može potaknuti građane na nasilje, a destabilizacija političkog sustava povećava neizvjesnost za ekonomske subjekte i negativno utječe na investicije i odluke o potrošnji.

## 2.4. Mjerenje korupcije

Korupcija posljednjih desetljeća privlači više pozornosti nego ranije. Postavlja se pitanje znači li to da je korupcija danas raširenija, ili joj se jednostavno pridaje više važnosti. Postoji nekolicina argumenata kojima se rast fenomena korupcije nastoji objasniti (Tanzi 1998, str. 4-6).

1. **Kraj Hladnoga rata** zaustavio je političko licemjerje zbog kojega se pojedinim režimima tolerirala politička korupcija, dok god su bili u ispravnom političkom bloku.
2. O korupciji u zemljama sa **centralno planiranim gospodarstvima** nerado se govorilo.
3. Rast broja država s **demokratskim vladama** i **slobodnim medijima** stvorio je ozračje u kojem rasprave o korupciji više nisu tabu tema.
4. **Globalizacija** je rezultirala čestim kontaktom između ljudi iz manje korumpiranih država i država gdje je korupcija endemska pojava.
5. **Nevladine organizacije**, poput *Transparency International*-a, a odnedavno i pojedine međunarodne financijske institucije, daju sve veći publicitet problemima koji nastaju kao rezultat korupcije, a većoj svijesti o istima doprinijele su i objavljene empirijske studije.
6. Veće oslanjanje na **tržišnu ekonomiju** znači i veći naglasak na efikasnosti, te poremećaji tržišta kakve uzrokuje korupcija privlače više pozornosti.
7. Američki kreatori politike smatraju kako su **američki izvoznici** mnogo izgubili u stranoj trgovini jer im je, prema američkim zakonima, zabranjeno davati mito stranim dužnosnicima, dok se istovremeno izvoznici iz drugih zemalja OECD-a nisu suočavali s takvom zabranom, premda se i to u zadnje vrijeme počelo mijenjati.
8. **Uloga države u ekonomiji** narasla je od 1960. godine naovamo, i to rastom oporezivanja, rastom javne potrošnje te povećanjem broja regulacija i kontrola u području ekonomije, što je dovelo do raznih oblika dozvola i autorizacija koje je potrebno ishoditi od javne administracije.

Napredak u suzbijanju korupcije na svim frontovima zahtijeva mjerenje same korupcije, kako bi se dijagnosticirali problemi i pratili rezultati. Ova spoznaja stvorila je interes kod Svjetske banke, donatora pomoći, primatelja pomoći, investitora i civilnog društva

za razvijanjem mjera korupcije, a to je nadalje potaklo nove rasprave o tome koji je najbolji način postizanja tog cilja (Kaufmann *et al*. 2006, str. 1). Vrlo brzo se pokazalo da, za razliku od tradicionalnih ekonometrijskih pokazatelja, mjerenje korupcije zahtijeva mnogo detaljnije konstrukcije i složene te često subjektivne ulazne podatke. To saznanje imalo je dvojak učinak na razvoj studija o korupciji. S jedne strane stvorilo je trend nepovjerenja prema nastojanjima suzbijanja korupcije, a ponajviše mogućnosti izrade mjerljivih pokazatelja i pouzdanih rezultata. S druge strane, kritike su potakle profesionalce i znanstvenike da razviju sofisticiranije i rigoroznije modele mjerenja. Kao posljedica toga, mjerenje korupcije privuklo je mnogo pozornosti i rezultiralo opsežnom literaturom i istraživanjima na tu temu (Urra 2007, str. 2).

Urra (2007, str. 3-4) razlikuje tri vrste pokazatelja korupcije: **objektivne**, **subjektivne** i **agregirane**. Objektivni pokazatelji, kakvi su u praksi vrlo rijetki, zapravo i nisu mnogo objektivniji od subjektivnih: i jedni i drugi temelje se na percepciji, doživljaju korupcije od strane ispitanika. Razlika je samo u tome što subjektivni pokazatelji uključuju i općenita pitanja, primjerice „Smatrate li da je Vaša vlada korumpirana?“, dok objektivni pokazatelji sužavaju područje ispitivanja na stvarna iskustva, a ne ideje, kako bi time isključili utjecaj pristranosti stavova. Konačno, agregirani pokazatelji, koji se računaju kombiniranjem više primarnih mjera, imaju četiri prednosti (Kaufmann i Kraay 2007, prema Urra 2007, str. 4): omogućuju obuhvat većeg broja država, pružaju funkcionalan sažetak iz više pojedinačnih pokazatelja, uprosječuju i time umanjuju greške mjerenja te utjecaj pristranosti pojedinačnih izvora, te omogućuju računanje granične pogreške.

Korupcija se mjeri na tri opća načina (Kaufmann *et al*. 2006, str. 2):

1. **Prikupljanjem mišljenja relevantnih dionika**, što uključuje anketiranje poduzeća, javnih dužnosnika, pojedinaca, vanjskih promatrača u nevladinim organizacijama, multilateralnih donatora te privatnog sektora. Ovi izvori podataka mogu se koristiti pojedinačno, ili u agregiranim pokazateljima koji kombiniraju više izvora, te su široko dostupni i pokrivaju velik broj država kroz višegodišnja razdoblja. Ovo je ujedno i jedina metoda kojom je moguće pratiti i uspoređivati korupciju na velikom uzorku država tijekom vremena.
2. **Praćenjem institucionalnih svojstava država**, čime se stječu informacije o prilikama i mogućnostima korupcije, poput procedura nabave, transparentnosti budžeta i sl. Time se ne mjeri sama korupcija, već samo naznake mogućnosti iste.

Podaci stečeni ovom metodom još uvijek su vrlo ograničeni, pogotovo u zemljama u razvoju, te praktički nemaju vremensku dimenziju.

3. **Pažljivom revizijom određenih projekata**, bilo financijskom revizijom, bilo detaljnijim usporedbama potrošnje i fizičkog *output*-a projekta. Takve revizije mogu pružiti informacije o malverzacijama u pojedinim projektima, no ne i o korupciji na državnoj razini. Prema tome, podaci stečeni ovom metodom nisu pogodni za usporedbe među državama ili za praćenje tijekom vremena.

### 2.4.1. CPI i WGI indeksi

**CPI indeks** (eng. *corruption perception index*) je agregirani pokazatelj korupcije kojeg na godišnjoj bazi objavljuje *Transparency International*. Podaci koje obuhvaća prikupljaju se iz različitih izvora (2015. godine ukupno 12), koji moraju zadovoljavati sljedeće kriterije:[10]

1. kvantificiraju percepciju korupcije u javnom sektoru,
2. temelje se na pouzdanoj metodologiji koja može rangirati više država na jednoj ljestvici,
3. prikupljaju ih vjerodostojne institucije na redovnoj bazi, te
4. omogućuju dovoljnu varijaciju rezultata da se države međusobno uspoređuju.

Nakon prikupljanja, podaci za svaku državu standardiziraju se statističkim metodama, na način da poprimaju vrijednosti na ljestvici od 0 do 100, gdje nula predstavlja najveći nivo korupcije, a 100 najmanji. Da bi neka država bila uključena u CPI, mora imati procjenu od strane najmanje tri izvora. CPI za svaku državu zatim se izračunava uprosječivanjem standardizirane vrijednosti pokazatelja iz svakog od dostupnih izvora, te se još izračunavaju i standardna greška te interval pouzdanosti.

Premda je CPI svjetski prihvaćena mjera korupcije, nailazio je na kritike u smislu nepreciznosti, nekonzistentnosti i realne nemogućnosti procjene što određeni stupanj korupcije konkretno znači za državu (Urra 2007, str. 4). Autori indeksa, međutim, ne bježe od kritika: svjesni su da je CPI ograničen u opsegu i da se svodi na *opažanja* poslovnjaka i

[10] http://files.transparency.org/content/download/1950/12812/file/2015_CPI_DataMethodologyZIP.zip [16.08.2016.]

stručnjaka, no isto tako ističu da je takva metoda mjerenja korupcije najpouzdaniji način za međusobno uspoređivanje država.[11]

**WGI pokazatelji** (eng. *Worldwide Governance Indicators*) rezultat su dugoročnog istraživačkog projekta razvoja pokazatelja koji se tiču vlasti, usporedivih među državama. WGI se sastoji od šest agregiranih pokazatelja dimenzija vlasti, koji pokrivaju više od 200 država od 1996. godine do danas. To su, kako slijedi: glas i odgovornost (eng. *voice and accountability*, VA), politička stabilnost i odsutnost nasilja i terorizma (PV), učinkovitost vlade (GE), kvaliteta regulacije (RQ), vladavina prava (RL) i kontrola korupcije (CC). Pokazatelji se temelje na nekoliko stotina varijabli prikupljenih iz 31 različitog izvora podataka, koji obuhvaćaju opažanja anketiranih osoba, nevladinih organizacija, pružatelja komercijalnih poslovnih informacija te organizacija iz javnog sektora diljem svijeta.

Podaci se, nakon prikupljanja, svrstavaju u šest skupina, u skladu sa šest spomenutih dimenzija vlasti. Za svaku od njih se potom, pomoću statističke metode poznate kao model neopaženih komponenti (eng. *unobserved components model*, UCM), vrši:

1. standardizacija raznolikih podataka, kako bi se isti mogli međusobno uspoređivati,
2. izračun agregiranog pokazatelja, kao i vaganog prosjeka izvornih varijabli,
3. izračun graničnih pogrešaka u kojima se ogleda neizbježna nepreciznost u mjerenju.

Od posebnog interesa korisnicima podataka koji proučavaju korupciju je upravo dostupnost pojedinačnih pokazatelja od kojih se WGI sastoji, s obzirom na komponentu „**kontrola korupcije**“ (CC). Pokazatelj CC obuhvaća opažanja i mišljenja o stupnju zlouporabe javnog utjecaja radi privatnih koristi, što uključuje i političku i birokratsku korupciju, kao i utjecaj elita i privatnih interesa na državu (Kaufmann *et al*. 2010, str. 2-5).

[11] http://files.transparency.org/content/download/1951/12816/file/2015_CPI_FAQsZIP.zip [16.08.2016.]

### 2.4.2. Problemi s mjerenjem korupcije

Velik izbor različitih pokazatelja korupcije nastao je kao rezultat velike količine informacija prikupljenih u posljednjih dvadesetak godina, kao i veće sofisticiranosti novih teoretskih modela koji objašnjavaju uzroke, posljedice i rješenja problema korupcije. Ta raznolikost predstavlja jasnu prednost pri mjerenju korupcije, jer se nedostaci jednog pokazatelja mogu kompenzirati prednostima drugoga. Također, korištenje raznolikih izvora znači i manje jednostranu procjenu te dostupniju informaciju (Urra 2007, str. 6).

Ipak, bez obzira na napredak, mjerenje korupcije i dalje se suočava s istim preprekama kao i prethodnih godina, koje se mogu svrstati u tri skupine: probleme percepcije, greške i korisnosti (Urra 2007, str. 6-9).

**Percepcija** je u korupciji bitna – to je opće prihvaćena činjenica – no isto tako je opće prihvaćeno i da nije sama po sebi dovoljna. Objektivni, stvarni podaci vrlo su traženi, ali su redovito oskudni ili čak nedostupni. Zbog toga se indeksi percepcije korupcije često tumače kao pokazatelji stvarnog stanja, čemu dodatno doprinose i složene statističke konstrukcije koje stvaraju dojam kvantitativne sofisticiranosti. U stvarnosti, studije pokazuju[12] da bi jaz između percipirane i stvarne korupcije mogao biti veći nego što se pretpostavlja, zbog potencijalno vrlo velikih graničnih vrijednosti pogreške. Iz tog razloga zavladao je velik pritisak za pribavljanjem „čvrstih, objektivnih podataka," no čak i kada su oni dostupni, i dalje može doći do sličnih razina greške jer zakonski propisi ne moraju nužno biti u skladu sa primjenom istih (Kraay 2006, prema Urra 2007, str. 7).

**Greška**. U sociološkim istraživanjima, modeli uvijek uključuju razinu pouzdanosti i graničnu pogrešku, koje se izračunavaju statističkim metodama, te sociolog mora uzeti u obzir neizvjesnost svojstvenu društvenim znanostima kada donosi zaključke i predviđanja. Međutim, njegovi ulazni podaci su egzaktni (npr. razine dohotka stanovnika različitih područja), dok se mjerenje korupcije suočava s velikim graničnim pogreškama već u ulaznim podacima, što dodatno otežava posao. Današnji pokazatelji korupcije sadržavaju i mjere pogreške: na primjer, interval pouzdanosti pokazatelja WGI iznosi rezultat plus/minus 1,64 iznosa standardne pogreške. Standardna pogreška izračunava se pomoću broja dostupnih izvora te procijenjene točnosti svakoga od njih. Tako će one opservacije s više izvora imati manji interval pouzdanosti (Kaufmann *et al*. 2003, prema Urra 2007, str. 7). Konačno

[12] Npr. Donchev i Ujhelyi (2007, str. 17); ili Bertrand i Mullainathan (2001); sve prema Urra (2007, str. 6).

agregiranje pokazatelja WGI ne vrši se jednostavnim uprosječivanjem, već se izvori važu prema njihovoj međusobnoj korelaciji (Kaufmann *et al*. 1999, prema Urra 2007, str. 7). Ova metoda, međutim, pretpostavlja da greške različitih izvora nisu međusobno korelirane, što Arndt i Oman (2006, prema Urra 2007, str. 8) osporavaju u četiri točke:

1. na izvore podataka za WGI utječe sam WGI,
2. na njih utječu i drugi kolege,
3. na percepcije utječu krize, dugoročni trendovi ili drugi egzogeni čimbenici poput stranih direktnih investicija,
4. tumačenje anketnih pitanja specifično je kontekstu i kulturi, stoga manje razlike u percepciji mogu jednostavno značiti da dijele istu pozadinu.

Spomenuti argumenti sugeriraju da je tobožnja neovisnost izvora podataka mnogo manja nego što se očekivalo, te da se stoga niska varijanca ulaznih podataka, i posljedično velik ponder u pokazatelju, može lako precijeniti.

**Korisnost**. Pokazatelji korupcije odavno se kritiziraju zbog preopćenitih ocjena iste, iz kakvih je teško izvesti konkretne smjernice za njezino suzbijanje. Stoga neke međunarodne agencije inzistiraju na novim, primjenjivim (eng. *actionable*) pokazateljima, koji mjere specifične aspekte korupcije koji su izravno vezani za političke odluke.[13] Jedan od nedostataka ovakvih pokazatelja jest što državna vlada može – ukoliko želi postići dobar rezultat pokazatelja, ali ne i suzbijati korupciju – tek prividno djelovati po pitanju obuhvaćenih elemenata. Na primjer, ako je jedan od elemenata pokazatelja postojanje službe za modernizaciju javnih usluga, vlada ga može jednostavno osnovati kako bi ispunila taj zahtjev, bez da se u stvarnosti bilo što mijenja.

U konačnici, mjerenje korupcije pokazuje se složenim zadatkom, podložnim nekolicini poteškoća od kojih su neke upravo spomenute. Ipak, trud i postignuća od strane znanstvenika na ovome području dokazuju da je mjerenje korupcije pozitivno evoluiralo, te da danas predstavlja dinamičan i poticajan izazov (Urra 2007, str. 8).

[13] Primjeri „primjenjivih" pokazatelja su *Organization for Economic Cooperation and Development – Development Assistance Committee* (DAC) ili *Procurement Indicators – Public Expenditure and Financial Accountability* (PEFA) pokazatelji.

# 3. PREGLED EMPIRIJSKIH ISTRAŽIVANJA ODNOSA POREZNOG SUSTAVA I KORUPCIJE

Jedna od čestih odlika literature koja se tiče korupcije, a pogotovo empirijskih doprinosa istoj, jest naglasak na egzogene čimbenike korupcije, koje su općenito izvan utjecaja državnih vlasti. U skladu s time, malo se zna o tome kako kreiranje državnih politika može utjecati na razinu korupcije u zemlji, premda se sve više prepoznaje uloga poreznih politika i politika potrošnje u poticanju odnosno suzbijanju korupcije (Liu i Feng 2015, str. 1). Empirijski podaci i saznanja o utjecaju poreznog sustava na korupciju oskudni su (Nawaz 2010, str. 4): postojeća literatura uglavnom se bavila suprotnom uzročnom vezom (Liu i Feng 2015, str. 2). Tek se posljednjih nekoliko godina provode studije koje bi trebale popuniti tu prazninu u literaturi, od kojih se pregled rezultata najvažnijih daje u nastavku.

## 3.1. Složenost poreznog sustava i korupcija

Ideja da složeniji porezni sustav stvara više mogućnosti za korupciju doima se smislenom: složenost poreznih propisa rezultira većim brojem mogućih tumačenja istih, što onda kod obveznika stvara inicijativu za odabirom onog tumačenja koje znači najmanju poreznu obvezu. Dakako, u diskreciji je službenika porezne uprave hoće li odabrati takvo tumačenje ili ne, a to istome donosi priliku za rentijersko ponašanje, odnosno zaradu određene „naknade“ za povoljan odabir. Ovakve situacije događaju se diljem svijeta, no u zemljama u razvoju, s manje „zrelim“ poreznim upravama, predstavljaju poseban problem koji negativno utječe na prihode od poreza, kao i na porezni moral (Awasthi i Bayraktar 2014, str. 2-3).

**Awasthi i Bayraktar (2014)** proveli su prvo istraživanje odnosa složenosti poreznog sustava i korupcije u poreznom sustavu na uzorku više zemalja. Kao mjerilo korupcije u poreznom sustavu koristili su se podaci na razini poduzeća iz 104 države, iz baze *Enterprise Survey Database* u izdanju Svjetske banke, u razdoblju od 2002. do 2012. godine. Složenost poreznog sustava mjerila se dvjema varijablama: vremenom plaćanja poreza te brojem plaćanja poreza, iz baze podataka *Doing Business*, također u izdanju Svjetske banke. Ovo su ujedno i jedina mjerila složenosti poreznog sustava koja se mogu uspoređivati među državama i/ili pratiti kroz vrijeme. Logika glasi da što je manje vremena potrebno uložiti u bavljenje poreznim sustavom, te što je manje plaćanja potrebno izvršiti, jednostavnije je poduzećima podmiriti svoje porezne obveze (2014, str. 3-5). Za analizu su također odabrane i

odgovarajuće ekonomske, političke, institucionalne, pravosudne i zemljopisne kontrolne varijable (2014, str. 17-25).

Panel regresijska analiza potvrdila je postojanje čvrste pozitivne veze između korupcije u poreznom sustavu i pokazatelja složenosti istoga, i to pri 1% značajnosti u većini provedenih testova. Po uvođenju kontrolnih varijabli, značajnost se zadržala, iako se smanjila (iznosila je do 10%), što se može objasniti pokazateljima demokratske odgovornosti, vladavine prava, kvalitete birokracije itd., koji svi također značajno utječu na korupciju u poreznom sustavu (2014, str. 25-28).

Daljnja analiza pokazala je da bi smanjenje broja poreznih plaćanja za 10% smanjilo korupciju u poreznom sustavu za 4%, dok bi skraćenje vremena plaćanja poreza za 10% istu zavisnu varijablu smanjilo za 6% – dakle, vrijeme plaćanja poreza pokazuje se pouzdanijom mjerom složenosti poreznog sustava. Kombinirani utjecaj dvaju spomenutih nezavisnih varijabli za 10% smanjio bi korupciju u poreznom sustavu za 9,6%, kontrolirajući za regionalne razlike i razlike u dohotku zemalja (2014, str. 28-31).

Nadalje, pokazalo se da je korupcija u poreznom sustavu osjetljivija na pojednostavljenje istoga u zemljama Latinske Amerike i Kariba te subsaharske Afrike, dok je najmanje osjetljiva u zemljama južne i istočne Azije te Pacifika.[14] Na sličan način, i u zemljama nižeg dohotka smanjenje broja poreznih plaćanja te skraćenje vremena plaćanja u većoj mjeri smanjuju korupciju u poreznom sustavu, nego u zemljama višeg dohotka. Ovi rezultati obećavajući su, jer sugeriraju da rad na pojednostavljivanju poreznih sustava u zemljama u razvoju itekako ima smisla (2014, str. 31-38).

**Liu i Feng (2015)** također su istraživali utjecaj složenosti poreznog sustava na korupciju, i to na nešto opsežnijem uzorku od 150 zemalja u razdoblju od 1995. do 2009. godine. Njihova argumentacija bila je, da što je porezni sustav složeniji i kompliciraniji, to je teže poreznim obveznicima procijeniti pravu „cijenu“ javnih dobara, odnosno koliko ih je financijski opteretilo plaćanje poreza iz kojih se ta javna dobra financiraju. Iz tog razloga bit će skloniji podržavati veću vladinu potrošnju, što će stvarati više prilika za korupciju. Nadalje, pod utjecajem fiskalne iluzije građani će biti manje motivirani za nadzor vlade i

[14] Ovdje vrijedi napomenuti da rezultati ankete o percepciji korupcije nisu sasvim u skladu sa rezultatima očekivanim na temelju promatranih slučajeva: primjerice, očekuje se da će korupcija biti veća u južnoj Aziji nego u Europi i srednjoj Aziji. Možebitni uzroci ovakvih rezultata su kulturološki čimbenici koji utječu na doživljaj korupcije kod ispitanika, te činjenica da nisu sve zemlje bile obuhvaćene istraživanjem (Awasthi i Bayraktar 2014, str. 31).

njezinih nedoličnih činova (2015, str. 59). Također, ukoliko su porezni zakoni teško razumljivi i mogu se protumačiti na više načina, korupcija može postati značajan problem u poreznoj administraciji (Tanzi 1998, str. 11-12), o čemu je već bilo riječi u drugom poglavlju.

Autori su se pri istraživanju, za razliku od Awasthija i Bayraktara (2014) koji su koristili panel analizu, služili *cross-country* regresijom, iz dva razloga: prvo, naveli su kako korupcija mnogo više varira između država nego što se mijenja tijekom vremena. Budući da je panel analiza sklona eliminaciji utjecaja između uzoraka (država) i fokusiranju na odnos unutar uzorka, autori smatraju kako ne bi mogla adekvatno objasniti varijancu korupcije. Drugo, složenost poreznog sustava općenito je stabilna varijabla tijekom dužih vremenskih razdoblja. Također, omjer direktnih i indirektnih poreza može pasti pod utjecaj kratkoročnih poslovnih ciklusa, zbog čega bi promatranje prosječnih vrijednosti ove varijable omogućilo jasniji uvid u dugoročni utjecaj porezne strukture na korupciju (2015, str. 60). Upravo iz tih razloga regresija će se koristiti i u ovom radu.

Kao kontrolne varijable odabrani su opći ekonomski, demografski, politički i kulturološki čimbenici korupcije, koji uključuju razine dohotka, gustoću naseljenosti, otvorenost, demokraciju, veličinu administracije, federalizam, decentralizaciju i dostupnost Interneta. Kako bi osigurali robusnost testova, autori su koristili više mjera korupcije (CPI, WGI i ICRG), te dvije mjere složenosti poreznog sustava: vrijeme i broj plaćanja, kao što su radili i Awasthi i Bayraktar (2014).

**Slika 4.** prikazuje tri dijagrama rasipanja koji stavljaju u odnos složenost poreznog sustava i korupciju. Na svakome od triju dijagrama kao mjerilo korupcije korišten je drugi pokazatelj od triju već spomenutih. Evidentno je kako postoji pozitivan odnos složenosti poreznog sustava i korupcije, što također opravdava provođenje regresijske analize u nastavku.

Rezultati regresijske analize potvrdili su vizualni dojam sa **Slike 4.**, i pokazali jasan pozitivan utjecaj složenosti poreznog sustava na korupciju u promatranome uzorku: u svih šest provedenih testova varijabla „vrijeme plaćanja poreza“ bila je statistički značajna pri razini od 1%. Od kontrolnih varijabli najznačajnije su bile „pristup Internetu“ (u svih šest testova uz najviše 5%) te „demokracija“ (u četiri od šest testova), što je u skladu sa stavovima da demokracija ima pozitivnu ulogu u suzbijanju demokracije, kao i Internet. Korištenje alternativnih varijabli u svrhu provjere robusnosti nije utjecalo na zaključke (Liu i Feng 2015, str. 67-69).

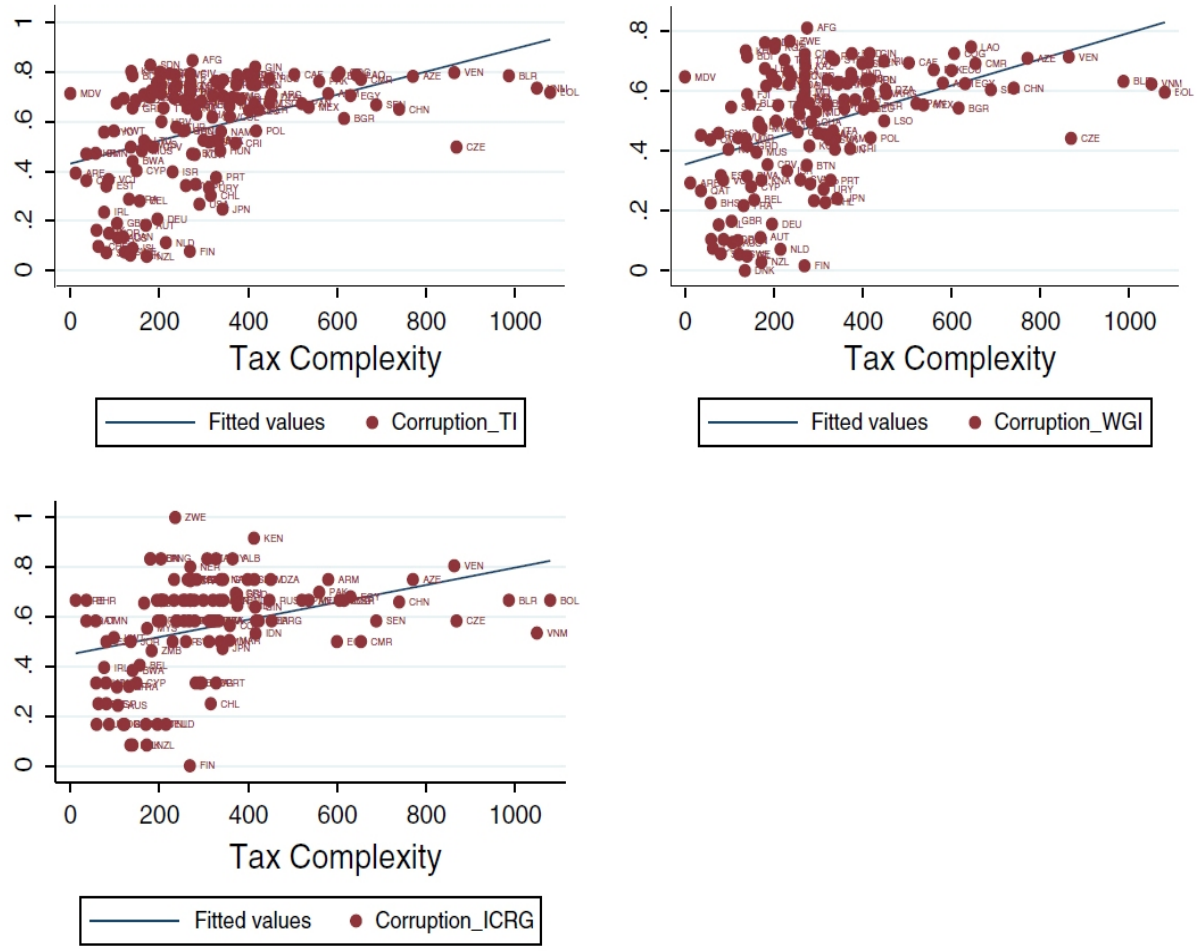


**Slika 4: Složenost poreznog sustava i korupcija**

Izvor: Liu i Feng (2015, str. 67, Fig. 2)

### 3.2. Porezna struktura i korupcija

Porezna struktura predstavlja novu determinantu korupcije, koju su istraživali **Liu i Feng (2015)**, zajedno sa složenošću poreznog sustava, spomenutom u prethodnom potpoglavlju. Radi se, zapravo, o omjeru direktnih i indirektnih poreza, što je pod izravnijom kontrolom vlasti nego složenost poreznog sustava. Logika je sljedeća: kod direktnih poreza predmet oporezivanja jest dohodak ili imovina poreznog obveznika, što čini ovu vrstu poreza transparentnijom, te smanjuje vjerojatnost prevaljivanja poreza. Nasuprot tome, indirektni porezi „skriveni“ su u cijenama dobara i usluga, što poreznom obvezniku otežava procjenu svojeg financijskog doprinosa realizaciji javnih programa. Navedeni fenomen produbljuje

fiskalnu iluziju i rezultira većom potražnjom za javnim dobrima, što u konačnici vodi većoj korupciji (2015, str. 58-60).

U kontekstu svog istraživanja, autori su direktnim porezima smatrali one poreze koji se mogu prilagoditi pojedinačnim karakteristikama obveznika (dohodak – osobni i korporativni, socijalno osiguranje i doprinosi), a indirektnima one koji se obračunavaju na transakcije neovisno o kupcu odnosno prodavatelju (porezi na imovinu, dobra i usluge, trošarine i carina). Podaci su prikupljani iz baze *Government Finance Statistics* (GFS) u izdanju Međunarodnog monetarnog fonda te baze *Revenue Statistics* u izdanju OECD-a.

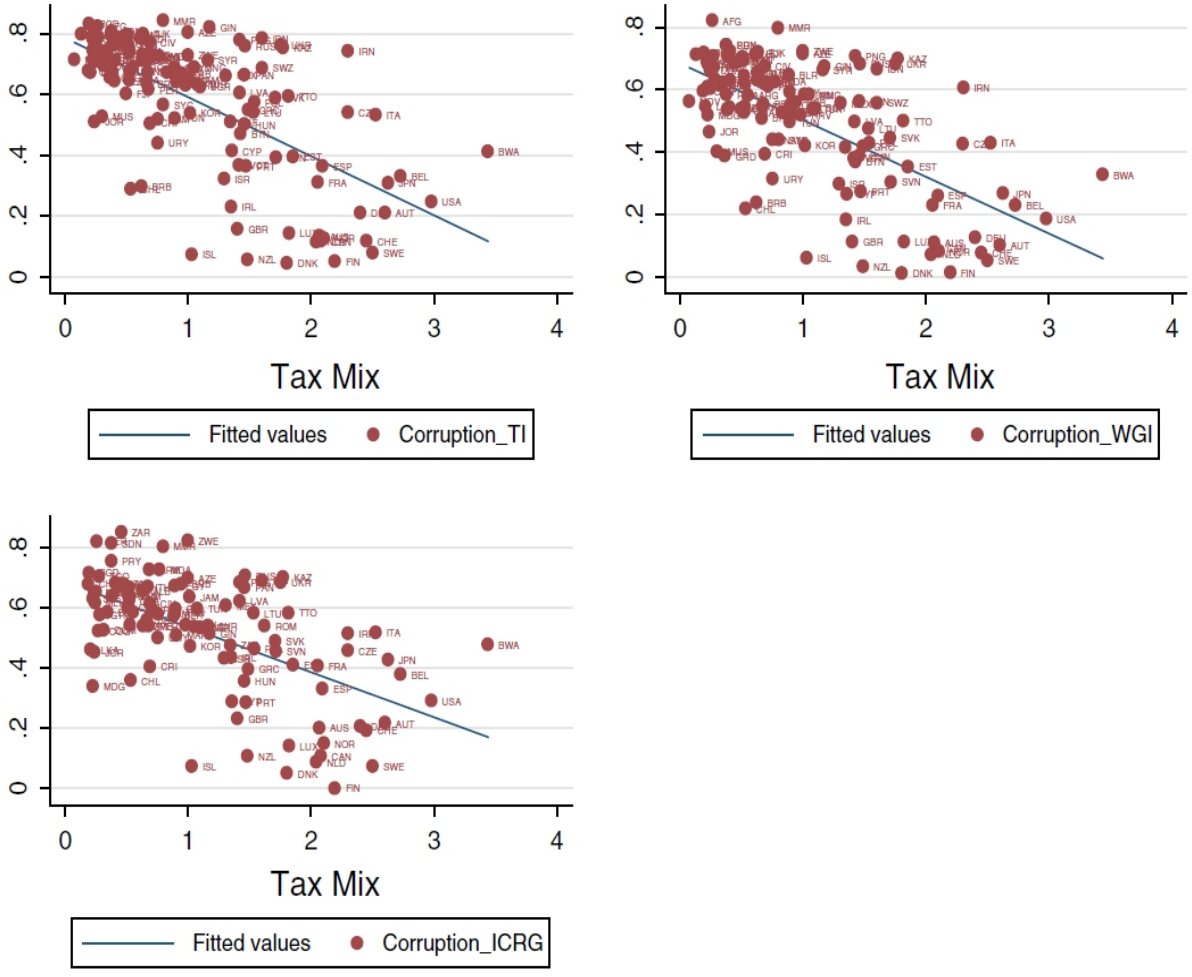


**Slika 5: Omjer direktnih i indirektnih poreza i korupcija**

Izvor: Liu i Feng (2015, str. 66, Fig. 1)

Na **Slici 5.** ponovno su prikazana tri dijagrama rasipanja s trima mjerilima korupcije na vertikalnoj osi, no ovoga puta s omjerom direktnih i indirektnih poreza na horizontalnoj

osi. Vidljiv je negativan odnos navedenog omjera i korupcije, što potvrđuju i rezultati provedene regresijske analize. Navedeni zaključak potvrđuje hipotezu autora da se države koje se više oslanjaju na direktne poreze suočavaju s manjom korupcijom. Rezultati su bili značajni u svih šest provedenih testova, uz iste kontrolne varijable kao i kod korištenja složenosti poreznog sustava kao nezavisne varijable, a ni provjera robusnosti nije utjecala na zaključak (2015, str. 65-74).

Autori zaključuju kako bi kreatori politike pri donošenju odluka o poreznoj strukturi, osim rasprava o njezinom utjecaju na ključne aspekte ekonomije, poput gospodarskog rasta i raspodjele dohotka, trebali voditi računa i o utjecaju porezne strukture na ostale aspekte društva, poput korupcije, imajući u vidu saznanja koja se stječu o istome (2015, str. 74).

# 4. EMPIRIJSKO ISTRAŽIVANJE UTJECAJA POREZNOG SUSTAVA NA KORUPCIJU

## 4.1. Podaci i metodologija istraživanja

Kao mjerilo **korupcije** za potrebe ovoga istraživanja koristit će se pokazatelj ***Control of Corruption*** iz baze podataka **WGI** (eng. *Worldwide Governance Indicators*), u izdanju Svjetske banke. Pokazatelji iz baze WGI oslanjaju se isključivo na percepciju, i sastoje se od anketa provedenih na poduzećima i kućanstvima, te subjektivnih procjena od strane komercijalnih pružatelja informacija o poslovanju, nevladinih udruga, te niza multilateralnih organizacija i ostalih tijela javnog sektora. Baza podataka WGI sastavljena je iz ukupno trideset i jednog izvora (Kaufmann *et al*. 2010, str. 5-6), a analiza će obuhvaćati razdoblje **od 2005. do 2014. godine**. Originalni pokazatelj može varirati od -2,5 (najveća korupcija) do 2,5 (najmanja korupcija), no za potrebe ovoga istraživanja preračunat je kako bi iznosio između nula (najveća korupcija) i 10 (najmanja korupcija).

U svrhu robusnosti, kao alternativna mjera korupcije koristit će se pokazatelj **CPI** (eng. *Corruption Perception Index*) u izdanju *Transparency International*-a. CPI je, međutim, dostupan samo u razdoblju od 2012. do 2015. godine, budući da je 2012. godine promijenjena metodologija izračunavanja pokazatelja: pokazatelj sada može iznositi od nula (najveća korupcija) do 100 (najmanja korupcija), zbog čega raniji podaci ne bi bili usporedivi s novijima (TI 2015, str. 2).

Na **Slici 6.** grafički su prikazani iznosi dvaju odabranih pokazatelja korupcije za zemlje obuhvaćene istraživanjem: CPI (prosječna vrijednost za razdoblje od 2012. do 2015.), te WGI (za razdoblje od 2005. do 2014. godine), uz napomenu da je pokazatelj WGI pomnožen s 10 radi preglednije vizualne usporedbe. Razvidno je da pokazatelji izrazito jako koreliraju: Pearsonov koeficijent korelacije iznosio je 97,6%, pri razini značajnosti od 1% (**Tablica 1.**). Nadalje, vidljive su i regionalne razlike u percepciji korupcije među državama: sjevernoeuropske, pogotovo skandinavske zemlje, suočavale su se s najmanjom razinom korupcije prema dostupnim pokazateljima, dok je najveća percepcija korupcije vladala u zemljama bivšeg Istočnog bloka, te južne i jugoistočne Europe, uključujući i Hrvatsku.

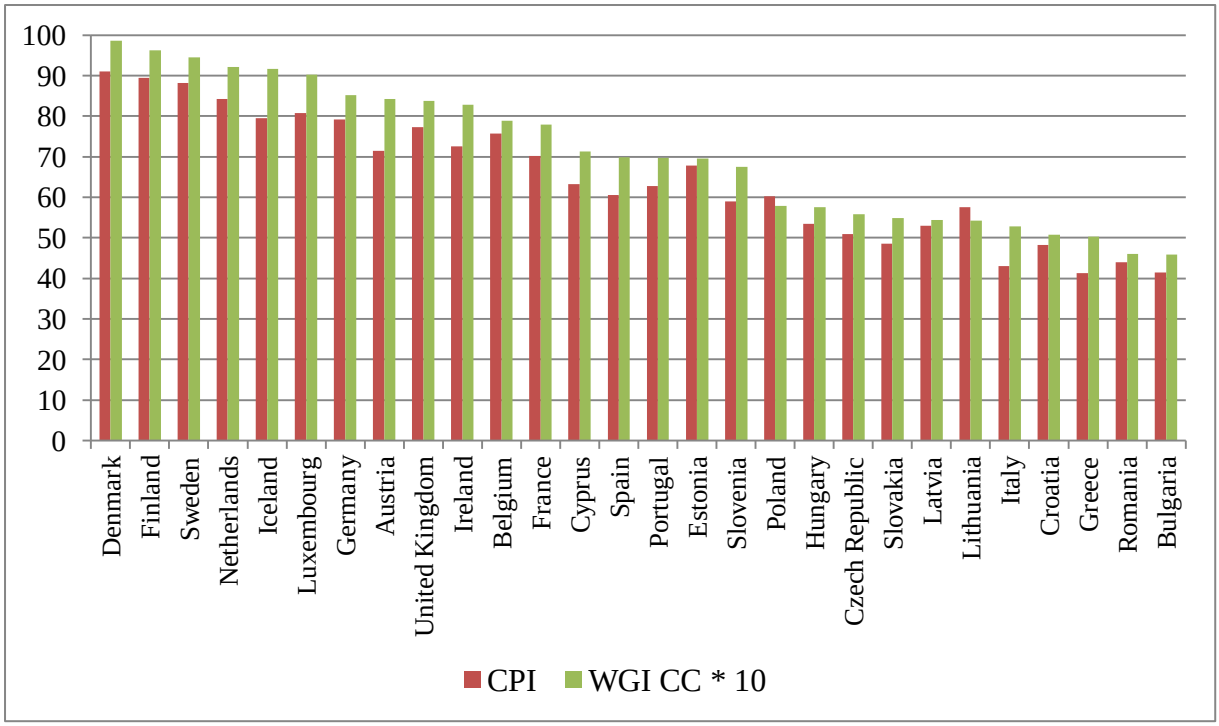


**Slika 6: Iznosi pokazatelja percepcije korupcije u zemljama Europske Unije**

Izvor: Svjetska banka, *Transparency International*; prikaz autora.

**Correlations**

| | | CPI (2012-15) | WGI CC (2005-14) |
|---|---|---|---|
| CPI (2012-15) | Pearson Correlation | 1 | ,976** |
| | Sig. (2-tailed) | | ,000 |
| | N | 28 | 28 |
| WGI CC (2005-14) | Pearson Correlation | ,976** | 1 |
| | Sig. (2-tailed) | ,000 | |
| | N | 28 | 28 |

**. Correlation is significant at the 0.01 level (2-tailed).

**Tablica 1: Pearsonov koeficijent korelacije između dvaju pokazatelja korupcije**

Izvor: Izračun autora.

Kao mjerilo **složenosti poreznog sustava** u ovome istraživanju koristit će se podaci iz publikacije Svjetske banke „*Doing Business,*" koja se bavi objektivnim mjerenjem regulacije poslovanja u 189 država (**Slika 7.**). Točnije, koristit će se varijabla *Time* iz skupine *Paying Taxes*, koja se odnosi na vrijeme potrebno za pripremu, evidenciju i plaćanje triju osnovnih vrsta davanja: korporativnog poreza na dobit, poreza na dodanu vrijednost te poreza na rad,

što uključuje doprinose iz plaće odnosno na plaću. Vrijeme pripreme uključuje prikupljanje svih informacija potrebnih za izračunavanje iznosa poreza koji je potrebno platiti; u vrijeme evidencije uračunava se vrijeme potrebno da se ispune svi obrasci porezne prijave te da se isti dostave poreznom autoritetu. Konačno, u vrijeme plaćanja uračunava se samo plaćanje, uživo ili preko Interneta, uključujući i eventualno čekanje. Varijabla se izražava u satima godišnje.[15] Podaci su dostupni u razdoblju **od 2006. do 2015. godine**.

Što se tiče **porezne strukture**, podaci o iznosima direktnih i indirektnih poreza prikupit će se iz baze podataka GFS (eng. *Government Finance Statistics*), u izdanju Međunarodnog monetarnog fonda, s tim da će se iznosi odnositi na sektor opće države (eng. *general government*) (**Slika 8.**). Pod direktne poreze, u skladu s načinom očitovanja porezne snage (Nikolić 1999, str. 94), svrstat će se porezi na dohodak, dobit, imovinu i kapitalne dobitke, te doprinosi iz plaće odnosno na plaću, a pod indirektne poreze svrstat će se opći porezi na dobra i usluge (PDV), trošarine te porezi na međunarodnu trgovinu i transakcije.

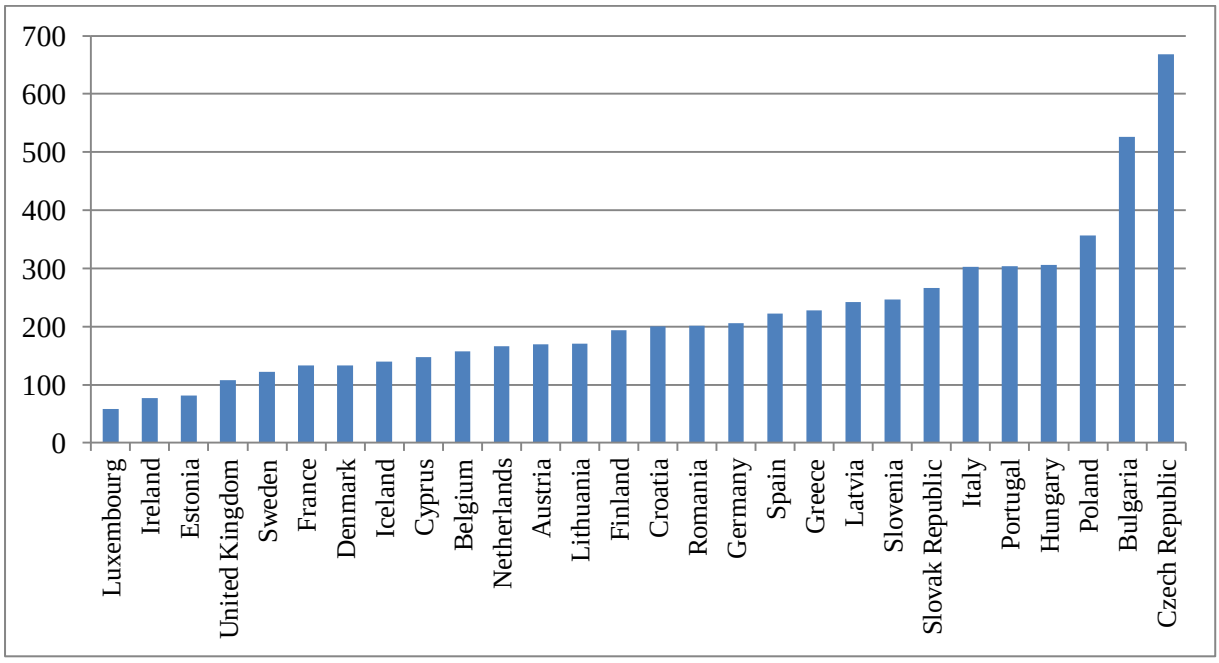


**Slika 7: Vrijeme potrebno za plaćanje poreza u zemljama EU, u satima godišnje (prosječne vrijednosti u razdoblju 2006.-15.)**

Izvor: Svjetska banka; prikaz autora.

[15] http://www.doingbusiness.org/methodology/paying-taxes [17.08.2016.]

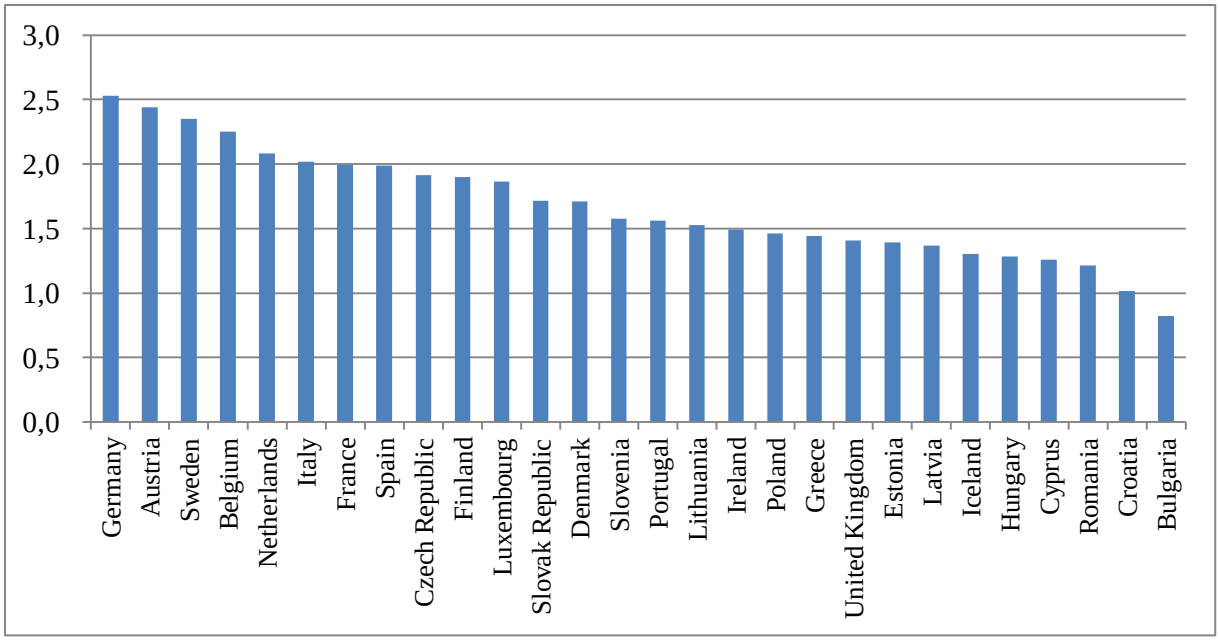


**Slika 8: Omjer direktnih i indirektnih poreza u zemljama EU (prosječne vrijednosti u razdoblju 2005.-14.)**

Izvor: Međunarodni monetarni fond; izračun i prikaz autora.

U istraživanju će se koristiti i odgovarajuće kontrolne varijable, i to, kako slijedi (Liu i Feng 2015, str. 61-62):

- **BDP**, kao pokazatelj dohotka države, kontrolirat će strukturne razlike među državama. Smatra se da bi veći dohodak trebao smanjiti potražnju za korupcijom, i time rezultirati nižim razinama korupcije, a istovremeno je i veća dostupnost resursa za suzbijanje iste.
- **Gustoća naseljenosti**. Veće države koriste se ekonomijom obujma pri pružanju javnih usluga, što znači manji omjer javnih usluga po glavi stanovnika. Kao rezultat toga, pojedinci će biti skloniji pokušaju podmićivanja javnih službenika kako bi „preskočili red.“
- **Otvorenost**, u ovom slučaju računata zbrojem uvoza i izvoza kao udjela u BDP-u, znači manje ograničenja u međunarodnoj trgovini, a upravo za takva ograničenja se smatra da pružaju prilike za korupciju.
- **Raširenost Interneta**, mjerena brojem korisnika na 100 stanovnika, odnedavno se smatra važnim alatom za suzbijanje korupcije na više načina: primjerice, Internet ubrzava širenje informacija, što povećava rizik otkrivanja nedoličnog ponašanja političara.

- **Uključenost žena u tržište rada**. Neke studije (npr. Swamy *et al*. 2001, prema Liu i Feng 2015, str. 61) sugeriraju da bi veća prisutnost žena na tržištu rada mogla negativno djelovati na korupciju, možebitno zbog njihove veće averzije prema riziku, odnosno procjene da je veća vjerojatnost otkrivanja koruptivnog djela.

Sve kontrolne varijable preuzete su iz baze podataka WDI (*World Development Indicators*), u izdanju Svjetske banke. Premda su u svojim istraživanjima Liu i Feng (2015, str. 75) te Awasthi i Bayraktar (2014, str. 20) koristili odgovarajući pokazatelj demokratičnosti, ovdje za time nije bilo potrebe, budući da su ovim istraživanjem obuhvaćene isključivo zemlje članice Europske Unije, od kojih velika većina ima najviše ocjene iz tog područja.[16] To i nije iznenađujuće, s obzirom da demokratičnost predstavlja jedan od uvjeta pristupanja Europskoj Uniji.[17]

Ispitivanje uzročnih veza između elemenata poreznog sustava i korupcije vršit će se pomoću **linearne *cross-country* regresije**. Razlog tome je, kao što je već spomenuto, to što korupcija mnogo više varira između država nego što se mijenja tijekom vremena. Stoga panel analiza ne bi bila odgovarajući izbor za ovo istraživanje. Osim toga, složenost poreznog sustava općenito je stabilna varijabla tijekom dužih vremenskih razdoblja (Liu i Feng 2015, str. 60).

[16] Prema pokazatelju *Freedom in the World* za 2016. godinu, u izdanju neprofitne organizacije *Freedom House*, sve zemlje članice Europske Unije klasificirane su kao „slobodne." Izvor: https://freedomhouse.org/report/freedom-world/freedom-world-2016 [14.08.2016.]
[17] http://ec.europa.eu/enlargement/policy/conditions-membership/index_en.htm [14.08.2016.]

## 4.2. Utjecaj složenosti poreznog sustava na korupciju

**Slika 9.** prikazuje dijagrame rasipanja koji stavljaju u odnos vrijeme plaćanja poreza i korupciju, s tim da se na lijevom grafu kao mjerilo korupcije koristi pokazatelj *Control of Corruption* iz baze WGI, a na desnom grafu alternativni pokazatelj CPI, od *Transparency International*-a. Vidljivo je da je korelacija u oba slučaja negativna,[18] odnosno da veći broj sati potreban za obavljanje svih radnji koje se tiču plaćanja poreza negativno korelira s kontrolom korupcije, što je u skladu s teorijskim predviđanjima.

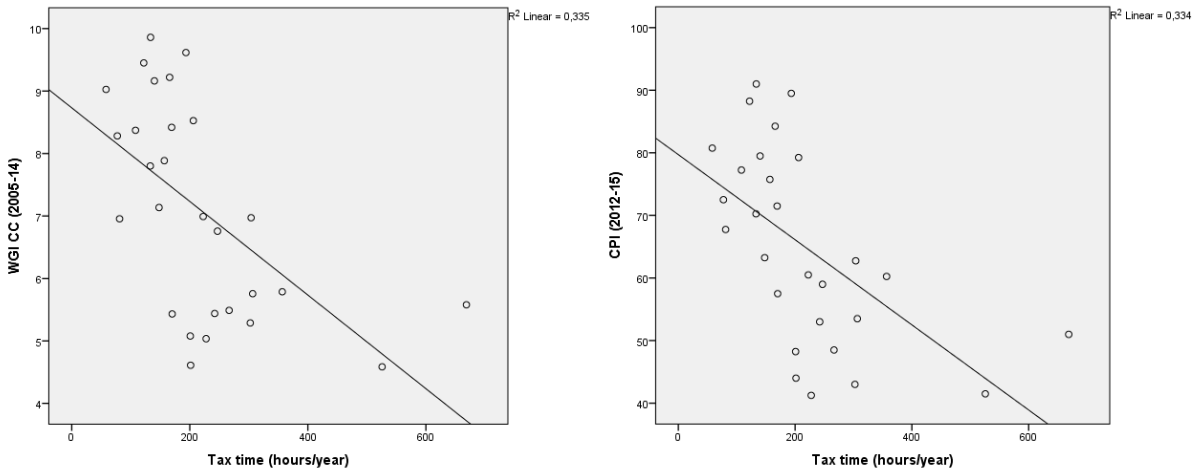


**Slika 9: Odnos složenosti poreznog sustava i korupcije**

Izvor: Prikaz autora.

Rezultati regresijske analize prikazani su u **Tablici 2**. U prvome stupcu vrijeme plaćanja poreza je jedina nezavisna varijabla, te rezultat potvrđuje vizualni dojam sa **Slike 9.**, tj. da je odnos složenosti poreznog sustava i kontrole nad korupcijom negativan, i to na razini značajnosti od 1%. U nastavku (stupac 2), u analizu su uvedene i kontrolne varijable, te je rezultat sljedeći: gustoća naseljenosti nije se pokazala značajnim utjecajem na korupciju, kao ni otvorenost, premda je značajnost u drugom slučaju bila tek neznatno iznad 10%. Raširenost Interneta, uključenost žena u tržište rada te BDP imali su pozitivan utjecaj na suzbijanje korupcije, što je u skladu s teorijskim pretpostavkama. U svrhu provjere robusnosti, u stupcu 3 kao zavisna varijabla korištena je alternativna mjera korupcije, te je rezultat, što se tiče značajnosti, bio gotovo identičan: u oba slučaja varijabla *Vrijeme plaćanja poreza* kao mjerilo složenosti poreznog sustava, zadržala je statističku značajnost, i to na razini od 5%.

[18] Pearsonov koeficijent korelacije između varijable *Vrijeme plaćanja poreza* te dvaju pokazatelja korupcije bio je gotovo identičan: -0,579 odnosno -0,578. Korelacija je bila značajna pri razini od 1%.

| | (1)<br>wgi cc | (2)<br>wgi cc | (3)<br>cpi |
|---|---|---|---|
| **Vrijeme plaćanja poreza** | **-0,007*****<br>**(0,002)** | **-0,003****<br>**(0,001)** | **-0,022****<br>**(0,010)** |
| Gustoća naseljenosti | | -0,001<br>(0,002) | -0,001<br>(0,015) |
| Otvorenost | | 0,007<br>(0,004) | 0,051<br>(0,036) |
| Raširenost Interneta | | 0,041**<br>(0,018) | 0,418**<br>(0,161) |
| Uključenost žena u tržište rada | | 0,120***<br>(0,042) | 1,016**<br>(0,385) |
| BDP (ln) | | 0,448**<br>(0,162) | 3,406**<br>(1,482) |
| *(Constant)* | 8,731***<br>(0,526) | -13,731**<br>(5,346) | -105,591**<br>(49,041) |
| *N* | 28 | 28 | 28 |
| $R^2$ | 0,335 | 0,877 | 0,875 |

**Tablica 2: Regresijska analiza utjecaja složenosti poreznog sustava na korupciju**
Izvor: Izračun i prikaz autora.

Također, u oba slučaja koeficijent multiple determinacije ($R^2$) premašivao je 87%, što ukazuje na visoku protumačenost i dobru reprezentativnost modela. Nadalje, uz regresijsku analizu provedeni su i određeni testovi u svrhu utvrđivanja značajnosti modela, odnosno postojanja uobičajenih problema u regresijskoj analizi (**Prilog 1.**):

- ANOVA F-test dao je rezultat α~0, što znači da je **model statistički značajan**.
- Durbin-Watsonov test iznosio je približno 2 => **ne postoji problem autokorelacije**.
- U provedenom testu kolinearnosti, faktor inflacije varijance (VIF) ni za jednu varijablu nije premašio 5 => **ne postoji problem multikolinearnosti**.
- **Reziduali su normalno distribuirani** s očekivanom vrijednošću nula i standardnom devijacijom od približno 1.

U skladu s navedenim, može se zaključiti da je model valjan, i time **prihvatiti hipotezu H1** o većoj korupciji u zemljama sa složenijim poreznim sustavima.

Rezultati ove regresijske analize u skladu su sa saznanjima iz dosadašnjih istraživanja. Vrijeme plaćanja poreza u istraživanju Liu i Feng (2015, str. 69) pokazalo se statistički značajnim pri 1%, dok je ovdje bilo značajno pri 5% s kontrolnim varijablama. Što se dotičnih tiče, raširenost Interneta, BDP i uključenost žena u tržište rada bili su statistički značajni i u istraživanju Liu i Fenga. Demokratičnost, koja je tamo također bila značajna, ovdje nije uvedena u analizu, iz već navedenih razloga.

Awasthi i Bayraktar (2014, str. 37-38) proveli su regresijsku analizu odvojeno za zemlje nižeg odnosno višeg dohodovnog ranga. Premda su i oni zaključili kako je utjecaj vremena plaćanja poreza na korupciju općenito pozitivan, taj se utjecaj pokazao mnogo jačim u zemljama u razvoju. S druge strane, regresijska analiza provedena u ovome radu obuhvaćala je zemlje članice Europske Unije, koje pretežno spadaju među razvijene, a vrijeme plaćanja poreza svejedno se pokazalo značajnim čimbenikom korupcije. Prema tome, rezultati ovoga istraživanja ukazuju da rad na pojednostavljivanju poreznog sustava ima smisla i u razvijenim zemljama.

### 4.3. Utjecaj porezne strukture na korupciju

Kao i u prethodnom potpoglavlju, analiza je započeta grafičkim prikazom odnosa promatrane nezavisne varijable s dvama pokazateljima korupcije (**Slika 10.**). Ponovno je utvrđena korelacija, ovoga puta pozitivna,[19] što znači da veći udio direktnih poreza u ukupnim porezima korelira s većom kontrolom korupcije, što je u skladu s teorijskim predviđanjima.

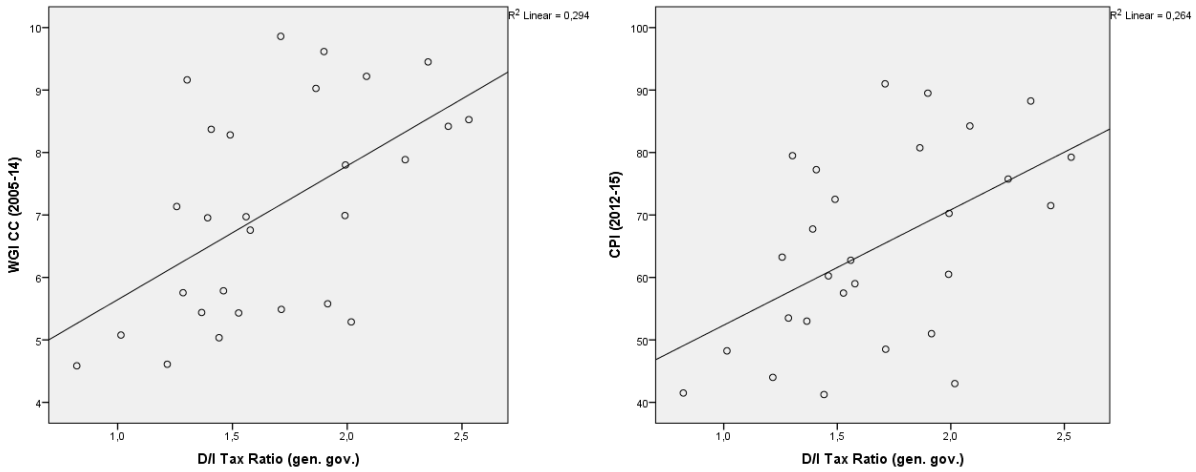


**Slika 10: Odnos porezne strukture i korupcije**

Izvor: Prikaz autora.

Rezultati regresijske analize prikazani su u **Tablici 3**. U prvome stupcu porezna struktura predstavljala je jedinu nezavisnu varijablu, te je rezultat potvrdio vizualni dojam sa **Slike 10.**, tj. da je odnos udjela direktnih poreza u ukupnim porezima i kontrole nad korupcijom pozitivan, i to na razini značajnosti od 1%.

Drugi stupac pokazuje da se, uvođenjem kontrolnih varijabli, značajnost promatranog koeficijenta izgubila. Međutim, valja primijetiti da je faktor inflacije varijance (VIF) za varijable *Raširenost Interneta* te *BDP (ln)* iznosio 4,768 odnosno 4,879, što je vrlo blizu graničnoj vrijednosti od 5 i upućuje na mogući problem multikolinearnosti (**Prilog 2.**). Kao što je poznato, multikolinearnost uzrokuje velike standardne pogreške ocijenjenih parametara i može navesti na zaključak kako dotični parametri nisu značajni ili da su gotovo beznačajni. Također, ocijenjeni koeficijenti postaju veoma osjetljivi na uključenje ili isključenje drugih nezavisnih varijabli (Rozga 2009, str. 198-199). Tablica korelacija nezavisnih varijabli (**Prilog 4.**) pokazuje da varijabla *Direktni / Indirektni porezi* doista korelira, i to srednje jako i

[19] Pearsonov koeficijent korelacije između varijable *Direktni / Indirektni porezi* te dvaju pokazatelja korupcije iznosio je 0,542 (WGI CC) odnosno 0,514 (CPI). Korelacija je bila značajna pri razini od 1%.

statistički značajno (pri razini od 1%), s dvjema varijablama s visokim faktorima inflacije varijance.

| | (1)<br>wgi cc | (2)<br>wgi cc | (3)<br>wgi cc | (4)<br>cpi |
|---|---|---|---|---|
| **Direktni / indirektni porezi** | **2,143*****<br>**(0,651)** | **0,243**<br>**(0,527)** | **1,735*****<br>**(0,472)** | **14,459*****<br>**(4,346)** |
| Gustoća naseljenosti | | -0,001<br>(0,002) | 0,002<br>(0,002) | 0,023<br>(0,018) |
| Otvorenost | | 0,007<br>(0,004) | 0,005<br>(0,003) | 0,044<br>(0,030) |
| Raširenost Interneta | | 0,046**<br>(0,020) | | |
| Uključenost žena u tržište rada | | 0,129**<br>(0,046) | 0,179***<br>(0,030) | 1,666***<br>(0,275) |
| BDP (ln) | | 0,423**<br>(0,202) | | |
| *(Constant)* | 3,502***<br>(1,124) | -14,829**<br>(6,155) | -5,934***<br>(1,711) | -53,969***<br>(15,743) |
| *N* | 28 | 28 | 28 | 28 |
| $R^2$ | 0,294 | 0,850 | 0,732 | 0,726 |

**Tablica 3: Regresijska analiza utjecaja porezne strukture na korupciju**

Izvor: Izračun i prikaz autora.

Stoga je u trećem stupcu **Tablice 3**. regresijska analiza ponovljena bez dvaju spornih varijabli, te je varijabla *Direktni / Indirektni porezi* ponovno postala statistički značajnom. Koeficijent determinacije ($R^2$) smanjio se, doduše, na 73,2%, no problem multikolinearnosti riješen je, a zadovoljeni su i ostali dijagnostički testovi provedeni i u prethodnom potpoglavlju (**Prilog 3.**). Radi robusnosti, u četvrtom stupcu analiza je ponovljena sa alternativnim pokazateljem korupcije, i rezultat se nije promijenio.

Slijedom svega navedenog, **hipoteza H2** o većoj korupciji u zemljama koje se više oslanjaju na indirektne poreze nego u zemljama koje se više oslanjaju na direktne poreze, također se može **prihvatiti**. Rezultat je u skladu sa zaključkom Liu i Fenga (2015, str. 68), uz napomenu da su u tom istraživanju od kontrolnih varijabli jedino raširenost Interneta i demokratičnost bili značajni pri 1%, dok ovdje nijedna od tih varijabli nije uključena.

Dobivena saznanja, s obzirom na utjecaj raznih ekonomskih i društvenih čimbenika na korupciju, ukazuju na potrebu stalnog iznalaženja novih metoda suzbijanja ovog upornog i sveprisutnog problema.

Konkretno, na temelju saznanja stečenih ovim istraživanjem, nameću se dva smjera djelovanja u Republici Hrvatskoj. Prvo, potrebno je pojednostavniti porezni sustav, što se može postići:

- skraćenjem vremena plaćanja poreza, primjerice omogućavanjem elektroničkog slanja digitalno potpisanih obrazaca u Poreznu upravu, na čemu se već radi,[20] a trebalo bi uštedjeti vrijeme utrošeno na čekanje u redovima;
- smanjenjem broja poreznih davanja, metoda plaćanja i učestalosti plaćanja. U Hrvatskoj se, na primjer, posljednjih godina dosta raspravljalo o smanjenju parafiskalnih nameta. Određeni, premda još uvijek malen napredak na ovome području za sada je postignut.[21]

Drugo, reforma poreznog sustava kojom bi se više prihoda prikupljalo direktnim porezima, a manje indirektnima, značila bi vjerojatno smanjenje PDV-a i odustajanje od poreza na nekretnine, a po potrebi povećanje poreza na dohodak i dobit. Ipak, rasprava o optimalnom omjeru direktnih i indirektnih poreza trebala bi u prvom planu imati utjecaj istoga na gospodarski rast i raspodjelu dohotka, no ni utjecaj na korupciju, kao što se odnedavno pokazuje, ne bi trebalo zanemarivati.

[20] http://www.porezna-uprava.hr/HR_ePorezna/Stranice/ePorezna.aspx [04.09.2016.]
[21] http://www.poslovni.hr/hrvatska/rezanje-155-mil-kuna-nameta-mali-ali-pozitivan-korak-315955 [04.09.2016.]

# 5. ZAKLJUČAK

Cilj ovoga istraživanja, s empirijskog stajališta, bio je ispitati utjecaj poreznog sustava na korupciju u zemljama članicama Europske Unije tijekom posljednjeg desetljeća. Aspekti poreznog sustava uključeni u ovo istraživanje bili su složenost poreznog sustava te porezna struktura. U svrhu ispunjenja cilja istraživanja, provedena je linearna regresijska analiza koja je ocijenjena boljom metodom od panel regresije, budući da korupcija mnogo više varira između država nego što se mijenja tijekom vremena. Također, složenost poreznog sustava dosad se pokazivala stabilnom varijablom tijekom dužih vremenskih razdoblja.

Kao mjerilo korupcije za potrebe ovoga istraživanja koristio se pokazatelj *Control of Corruption* iz baze podataka WGI (eng. *Worldwide Governance Indicators*), u izdanju Svjetske banke. U svrhu robusnosti, kao alternativna mjera korupcije koristio se pokazatelj CPI (eng. *Corruption Perception Index*) u izdanju *Transparency International*-a. Kao pokazatelj složenosti poreznog sustava koristilo se vrijeme potrebno za pripremu, evidenciju i plaćanje poreznih davanja, izraženo u satima godišnje, iz publikacije Svjetske banke „*Doing Business.*“ Porezna struktura odnosila se na omjer direktnih i indirektnih poreza, a isti su se razvrstavali sukladno načinu očitovanja porezne snage. Podaci o iznosima poreza preuzeti su iz baze podataka GFS (eng. *Government Finance Statistics*), u izdanju Međunarodnog monetarnog fonda, i to za sektor opće države (eng. *general government*).

Između varijable *Vrijeme plaćanja poreza* i kontrole nad korupcijom utvrđena je negativna i statistički značajna korelacija, što je u skladu s teorijskim predviđanjima. Regresijska analiza potvrdila je tu vezu, koja je zadržala statističku značajnost i nakon uvođenja kontrolnih varijabli, i to gustoće naseljenosti, otvorenosti (zbroja izvoza i uvoza kao udjela u BDP-u), raširenosti Interneta, uključenosti žena u tržište rada te BDP-a. Izračunati regresijski model zadovoljio je odgovarajuće dijagnostičke testove, stoga je **hipoteza H1, o većoj korupciji u zemljama sa složenijim poreznim sustavima, prihvaćena**.

Što se tiče omjera direktnih i indirektnih poreza i kontrole nad korupcijom, utvrđena je pozitivna i značajna korelacija, što je, kao i u prethodnom slučaju, potvrdila regresijska analiza, te je također bilo u skladu s teorijskim očekivanjima. U nastavku analize, međutim, utvrđen je moguć problem multikolinearnosti između promatrane nezavisne varijable i dvaju kontrolnih varijabli (*Raširenost Interneta* i *BDP*), što je utjecalo na parametre i njihovu značajnost. Uklanjanjem spornih varijabli iz modela, omjer direktnih i indirektnih poreza

povratio je statističku značajnost, čime je, s obzirom da su tada svi dijagnostički testovi ponovno zadovoljeni, **prihvaćena i hipoteza H2 o većoj korupciji u zemljama koje se više oslanjaju na indirektne poreze nego u zemljama koje se više oslanjaju na direktne poreze.**

Doprinos ovoga istraživanja ogleda se u činjenici da je proučavanje utjecaja poreznog sustava na korupciju relativna novost u literaturi: sve do prije nekoliko godina nije bilo dovoljno empirijskih saznanja, budući da su se studije ovih područja uglavnom bavile suprotnom uzročnom vezom. Rezultati novih istraživanja utvrdili su postojanu vezu između složenosti poreznog sustava i korupcije, a isto vrijedi i za vezu porezne strukture i korupcije. Ovo saznanje navodi na zaključak kako borba protiv korupcije u razvijenim zemljama nije ništa manje važna nego u zemljama u razvoju, te kako bi nova istraživanja o utjecaju raznih ekonomskih i društvenih čimbenika na korupciju trebala inspirirati kreatore politike da stalno iznalaze nove metode suzbijanja ovog upornog i sveprisutnog problema.

Konkretno, na temelju saznanja, nameću se dva smjera djelovanja za Republiku Hrvatsku. Prvo, potrebno je pojednostavniti porezni sustav, što se može postići skraćenjem vremena plaćanja poreza, primjerice omogućavanjem elektroničkog slanja digitalno potpisanih obrazaca u Poreznu upravu, ili pak smanjenjem broja poreznih davanja, metoda plaćanja i učestalosti plaćanja. Drugo, potrebna je i reforma poreznog sustava kojom bi se više prihoda u odnosu na danas prikupljalo direktnim porezima, a manje indirektnima. Ipak, rasprava o optimalnom omjeru direktnih i indirektnih poreza u obzir treba uzeti i karakteristike pojedine zemlje, kao i utjecaj na gospodarski rast i raspodjelu dohotka, a ne samo na korupciju.

# LITERATURA


1. Aghion, P., Akcigit, U., Cagé, J., Kerr, W. R. (2016): **Taxation, Corruption and Growth**, NBER Working Paper 21928, Cambridge (MA): *National Bureau of Economic Research*, dostupno na: http://www.nber.org/papers/w21928.pdf [17.08.2016.]
2. Aidt, T. S. (2003): **Economic Analysis of Corruption: A Survey**, *The Economic Journal*, Vol. 113, No. 491, Features (Nov., 2003), *Blackwell Publishing*, str. F632-F652, dostupno na: http://projects.iq.harvard.edu/gov2126/files/aidt_2003.pdf [17.08.2016.]
3. Amundsen, I. (1999): **Political Corruption: An Introduction to the Issues**, Bergen: Chr. Michelsen Institute, WP 1999:7, dostupno na: http://www.cmi.no/publications/file/1040-political-corruption.pdf [17.08.2016.]
4. Attila, G. (2008): **Corruption, taxation and economic growth: theory and evidence**, CERDI working paper E 2008.29, Clermont: University of Auvergne, dostupno na: http://papers.ssrn.com/sol3/papers.cfm?abstract_id=2260995 [17.08.2016.]
5. Awasthi, R., Bayraktar, N. (2014): **Can Tax Simplification Help Lower Tax Corruption?**, Policy Research Working Paper No. 6988, *World Bank*, dostupno na: http://papers.ssrn.com/sol3/papers.cfm?abstract_id=2475075 [17.08.2016.]
6. Dreher, A., Herzfeld, T. (2005): **The Economic Costs of Corruption: A Survey and New Evidence**, SSRN: http://dx.doi.org/10.2139/ssrn.734184 [17.08.2016.]
7. European Commission (2015): **The European Union explained: Taxation**, Luxembourg: Publications Office of the European Union, dostupno na: http://bookshop.europa.eu/en/taxation-pbNA0115038/downloads/NA-01-0115038-038-EN-C/NA0115038ENC_002.pdf?FileName=NA0115038ENC_002.pdf&SKU=NA0115038ENC_PDF&CatalogueNumber=NA-01-0115038-038-EN-C [17.08.2016.]
8. Gordon, R. H., Nielsen, S. B. (1996): **Tax avoidance and value-added vs. income taxation in an open economy**, NBER Working Paper 5527, Cambridge (MA): *National Bureau of Economic Research*, dostupno na: http://www.nber.org/papers/w5527.pdf [17.08.2016.]

9. International Monetary Fund (2016): **Corruption: Costs and Mitigating Strategies**, *IMF Staff Discussion Note*, May 2016, Autor, dostupno na: http://www.imf.org/external/pubs/ft/sdn/2016/sdn1605.pdf [17.08.2016.]

10. Jelčić, B. (1997): **Javne financije**, Zagreb: *Informator*.

11. Kaufmann, D., Kraay, A., Mastruzzi, M. (2006): **Measuring Corruption: Myths and Realities**, *World Bank*, dostupno na: http://www1.worldbank.org/publicsector/anticorrupt/corecourse2007/Myths.pdf [17.08.2016.]

12. Kaufmann, D., Kraay, A., Mastruzzi, M. (2010): **The Worldwide Governance Indicators: Methodology and Analytical Issues**, Policy Research Working Paper No. 5430, *World Bank*, dostupno na: http://papers.ssrn.com/sol3/papers.cfm?abstract_id=1682130 [17.08.2016.]

13. Keen, M., Smith, S. (2007): **VAT Fraud and Evasion: What Do We Know, and What Can Be Done?**, IMF Working Paper WP/07/31, *International Monetary Fund*, dostupno na: https://www.imf.org/external/pubs/ft/wp/2007/wp0731.pdf [17.08.2016.]

14. Liu, Y., Feng, H. (2015): **Tax structure and corruption: cross-country evidence**, *Public Choice* No. 162, New York: *Springer*, str. 57-78.

15. Mauro, P. (1998): **Corruption and the composition of government expenditure**, *Journal of Public Economies* 69 (1998), str. 263-279, dostupno na: http://www1.worldbank.org/publicsector/anticorrupt/CoreCourse2005/Mauro.pdf [16.08.2016.]

16. Nawaz, F. (2010): **Exploring the Relationships between Corruption and Tax Revenue**, *U4 Expert Answers*, 228/2010., dostupno na: http://www.u4.no/publications/exploring-the-relationships-between-corruption-and-tax-revenue/downloadasset/421 [17.08.2016.]

17. Nikolić, N. (1999): **Počela javnog financiranja**, Split: Sveučilište u Splitu – Ekonomski fakultet.

18. Organisation for Economic Co-operation and Development (2016): **Corruption in Public Procurement**, dostupno na:

http://www.oecd.org/gov/ethics/Corruption-in-Public-Procurement-Brochure.pdf [16.08.2016.]

19. Pivac, S. (2010): **Statističke metode (predavanja, diplomski studij, kolegij „Statističke metode"), e-nastavni materijal**, Split: Sveučilište u Splitu – Ekonomski fakultet, ISBN 978-953-281-033-2.
20. Rozga, A. (2009): **Statistika za ekonomiste**, Split: Sveučilište u Splitu – Ekonomski fakultet.
21. Sargent, T. J., Wallace, N. (1981): **Some Unpleasant Monetarist Arithmetic**, *Quarterly Review* – Fall 1981, Federal Reserve Bank of Minneapolis, dostupno na: https://www.minneapolisfed.org/research/qr/qr531.pdf [17.08.2016.]
22. Tanzi, V. (1998): **Corruption Around the World: Causes, Consequences, Scope and Cures**, IMF WP/98/63, *International Monetary Fund*, dostupno na: https://www.imf.org/external/pubs/ft/wp/wp9863.pdf [17.08.2016.]
23. Tanzi, V., Davoodi, H. R. (2000): **Corruption, Growth and Public Finances**, IMF Working Paper WP/00/182, *International Monetary Fund*, dostupno na: http://www.imf.org/external/pubs/ft/wp/2000/wp00182.pdf [17.08.2016.]
24. Transparency International (2015): **Corruption Perception Index 2015: Frequently Asked Questions**, dostupno na: http://files.transparency.org/content/download/1951/12816/file/2015_CPI_FAQsZIP.zip [14.08.2016.]
25. Urra, F. J. (2007): **Assessing Corruption – An analytical review of Corruption measurement and its problems: Perception, Error and Utility**, Edmund A. Walsh School of Foreign Service, Georgetown University, dostupno na: www.u4.no/recommended-reading/assessing-corruption-an-analytical-review-of-corruption-measurement-and-its-problems-perception-error-and-utility/download [14.08.2016.]
26. Vargas-Hernández, J. G. (2009): **The Multiple Faces of Corruption: Typology, Forms and Levels**, SSRN: http://dx.doi.org/10.2139/ssrn.1413976 [17.08.2016.]
27. Zelenika, R. (2000): **Metodologija i tehnologija izrade znanstvenog i stručnog djela**, Rijeka: Ekonomski fakultet.

# POPIS TABLICA

Tablica 1: Pearsonov koeficijent korelacije između dvaju pokazatelja korupcije .....37

Tablica 2: Regresijska analiza utjecaja složenosti poreznog sustava na korupciju.....42

Tablica 3: Regresijska analiza utjecaja porezne strukture na korupciju.....45

# POPIS SLIKA

Slika 1: Ponuda, potražnja i cijena racioniranog dobra .....15

Slika 2: Korupcija i visina plaće u javnom sektoru.....17

Slika 3: Prihodi od poreza i korupcija .....20

Slika 4: Složenost poreznog sustava i korupcija .....33

Slika 5: Omjer direktnih i indirektnih poreza i korupcija.....34

Slika 6: Iznosi pokazatelja percepcije korupcije u zemljama Europske Unije .....37

Slika 7: Vrijeme potrebno za plaćanje poreza u zemljama EU, u satima godišnje (prosječne vrijednosti u razdoblju 2006.-15.).....38

Slika 8: Omjer direktnih i indirektnih poreza u zemljama EU (prosječne vrijednosti u razdoblju 2005.-14.) .....39

Slika 9: Odnos složenosti poreznog sustava i korupcije.....41

Slika 10: Odnos porezne strukture i korupcije.....44

# PRILOZI

**Prilog 1.** Vrijeme plaćanja poreza i sve kontrolne varijable.

**Model Summary[b]**

| Model | R | R Square | Adjusted R Square | Std. Error of the Estimate | Durbin-Watson |
|---|---|---|---|---|---|
| 1 | ,937[a] | ,877 | ,842 | ,67626421 | 1,994 |

a. Predictors: (Constant), Ln (GDP), Tax time (hours/year), Female labor participation (15+), Population density (/km2), Openness (Import+Export) /GDP, Internet users (/100 people)

b. Dependent Variable: WGI CC (2005-14)

**ANOVA[a]**

| Model | | Sum of Squares | df | Mean Square | F | Sig. |
|---|---|---|---|---|---|---|
| 1 | Regression | 68,546 | 6 | 11,424 | 24,980 | ,000[b] |
| | Residual | 9,604 | 21 | ,457 | | |
| | Total | 78,150 | 27 | | | |

a. Dependent Variable: WGI CC (2005-14)

b. Predictors: (Constant), Ln (GDP), Tax time (hours/year), Female labor participation (15+), Population density (/km2), Openness (Import+Export)/GDP, Internet users (/100 people)

**Coefficients[a]**

| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. | Collinearity Statistics | |
|---|---|---|---|---|---|---|---|---|
| | | B | Std. Error | Beta | | | Tolerance | VIF |
| 1 | (Constant) | -13,731 | 5,346 | | -2,569 | ,018 | | |
| | Tax time (hours/year) | -,003 | ,001 | -,195 | -2,228 | ,037 | ,767 | 1,304 |
| | Population density (/km2) | -,001 | ,002 | -,032 | -,319 | ,753 | ,573 | 1,744 |
| | Openness (Import+Export)/GDP | ,007 | ,004 | ,221 | 1,668 | ,110 | ,333 | 3,001 |
| | Internet users (/100 people) | ,041 | ,018 | ,383 | 2,359 | ,028 | ,222 | 4,509 |
| | Female labor participation (15+) | ,120 | ,042 | ,442 | 2,854 | ,009 | ,244 | 4,092 |
| | Ln (GDP) | ,448 | ,162 | ,415 | 2,776 | ,011 | ,262 | 3,814 |

a. Dependent Variable: WGI CC (2005-14)

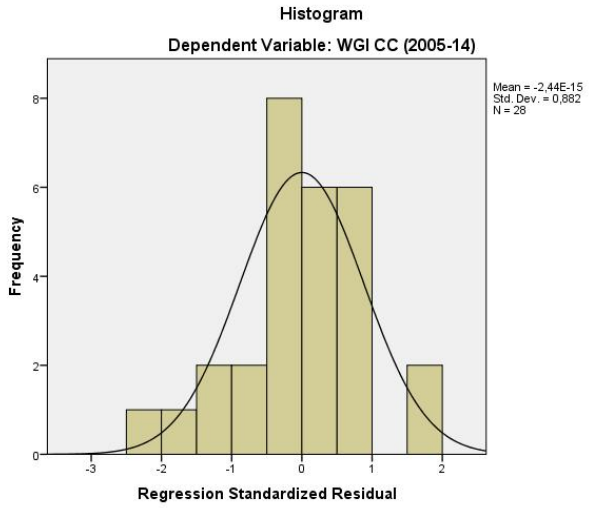


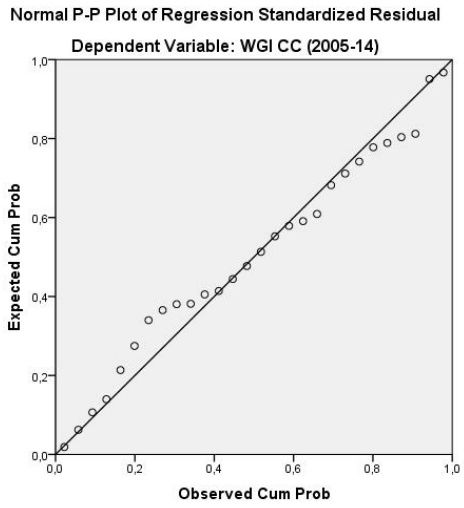

**Prilog 2.** Porezna struktura i sve kontrolne varijable.

**Model Summary[b]**

| Model | R | R Square | Adjusted R Square | Std. Error of the Estimate | Durbin-Watson |
|---|---|---|---|---|---|
| 1 | ,922[a] | ,850 | ,807 | ,74815894 | 2,374 |

a. Predictors: (Constant), Ln (GDP), Internet users (/100 people), Population density (/km2), Openness (Import+Export)/GDP, D/I Tax Ratio (gen. gov.), Female labor participation (15+)

b. Dependent Variable: WGI CC (2005-14)

**ANOVA[a]**

| Model | | Sum of Squares | df | Mean Square | F | Sig. |
|---|---|---|---|---|---|---|
| 1 | Regression | 66,396 | 6 | 11,066 | 19,770 | ,000[b] |
| | Residual | 11,755 | 21 | ,560 | | |
| | Total | 78,150 | 27 | | | |

a. Dependent Variable: WGI CC (2005-14)

b. Predictors: (Constant), Ln (GDP), Internet users (/100 people), Population density (/km2), Openness (Import+Export)/GDP, D/I Tax Ratio (gen. gov.), Female labor participation (15+)

**Coefficients[a]**

| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. | Collinearity Statistics | |
|---|---|---|---|---|---|---|---|---|
| | | B | Std. Error | Beta | | | Tolerance | VIF |
| 1 | (Constant) | -14,829 | 6,155 | | -2,409 | ,025 | | |
| | D/I Tax Ratio (gen. gov.) | ,243 | ,527 | ,061 | ,461 | ,649 | ,403 | 2,479 |
| | Population density (/km2) | -,001 | ,002 | -,039 | -,347 | ,732 | ,573 | 1,747 |
| | Openness (Import+Export)/GDP | ,007 | ,004 | ,232 | 1,562 | ,133 | ,326 | 3,072 |
| | Internet users (/100 people) | ,046 | ,020 | ,424 | 2,292 | ,032 | ,210 | 4,768 |
| | Female labor participation (15+) | ,129 | ,046 | ,475 | 2,786 | ,011 | ,246 | 4,063 |
| | Ln (GDP) | ,423 | ,202 | ,392 | 2,095 | ,049 | ,205 | 4,879 |

a. Dependent Variable: WGI CC (2005-14)

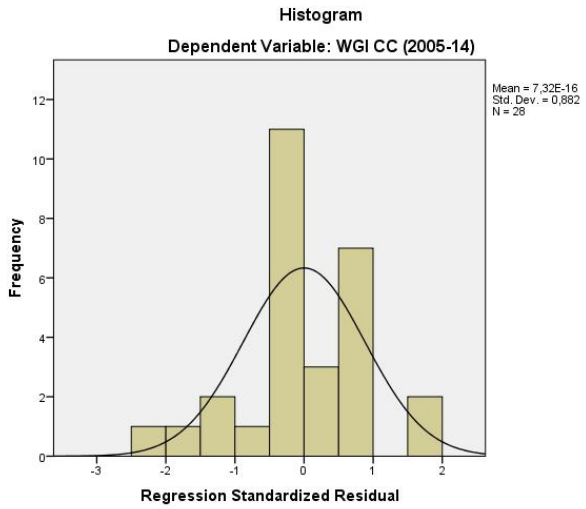


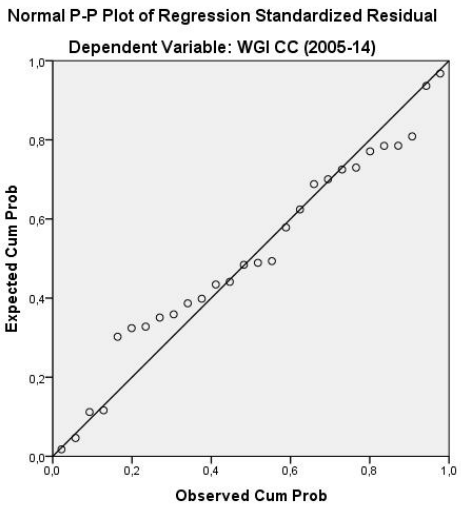

**Prilog 3.** Porezna struktura i kontrolne varijable, bez dviju isključenih.

**Model Summary[b]**

| Model | R | R Square | Adjusted R Square | Std. Error of the Estimate | Durbin-Watson |
|---|---|---|---|---|---|
| 1 | ,856[a] | ,732 | ,685 | ,95415273 | 2,003 |

a. Predictors: (Constant), Female labor participation (15+), Openness (Import+Export)/GDP, D/I Tax Ratio (gen. gov.), Population density (/km2)

b. Dependent Variable: WGI CC (2005-14)

**ANOVA[a]**

| Model | | Sum of Squares | df | Mean Square | F | Sig. |
|---|---|---|---|---|---|---|
| 1 | Regression | 57,211 | 4 | 14,303 | 15,710 | ,000[b] |
| | Residual | 20,939 | 23 | ,910 | | |
| | Total | 78,150 | 27 | | | |

a. Dependent Variable: WGI CC (2005-14)

b. Predictors: (Constant), Female labor participation (15+), Openness (Import+Export) /GDP, D/I Tax Ratio (gen. gov.), Population density (/km2)

**Coefficients[a]**

| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. | Collinearity Statistics | |
|---|---|---|---|---|---|---|---|---|
| | | B | Std. Error | Beta | | | Tolerance | VIF |
| 1 | (Constant) | -5,934 | 1,711 | | -3,467 | ,002 | | |
| | D/I Tax Ratio (gen. gov.) | 1,735 | ,472 | ,439 | 3,671 | ,001 | ,815 | 1,228 |
| | Population density (/km2) | ,002 | ,002 | ,138 | 1,129 | ,270 | ,781 | 1,280 |
| | Openness (Import+Export)/GDP | ,005 | ,003 | ,151 | 1,380 | ,181 | ,970 | 1,030 |
| | Female labor participation (15+) | ,179 | ,030 | ,661 | 5,986 | ,000 | ,956 | 1,046 |

a. Dependent Variable: WGI CC (2005-14)

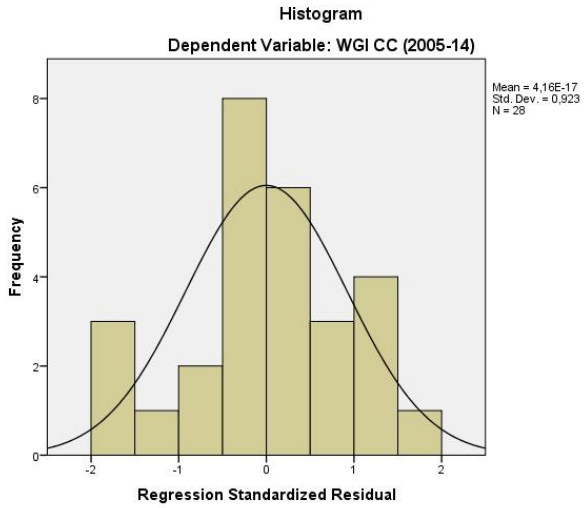


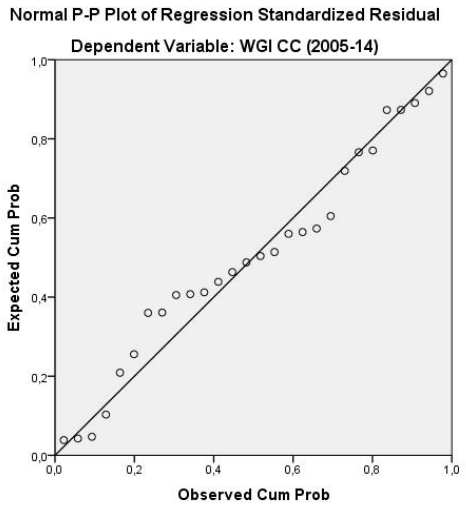

**Prilog 4.** Tablica korelacija nezavisnih varijabli, Pearson

**Correlations**

| | | Tax time (hours/year) | D/I Tax Ratio (gen. gov.) | Population density (/km2) | Openness (Import+Export)/GDP | Internet users (/100 people) | Female labor participation (15+) | Ln (GDP) |
|---|---|---|---|---|---|---|---|---|
| Tax time (hours/year) | Pearson Correlation | 1 | -,174 | -,063 | -,147 | -,473* | -,364 | -,029 |
| | Sig. (2-tailed) | | ,377 | ,752 | ,455 | ,011 | ,057 | ,885 |
| | N | 28 | 28 | 28 | 28 | 28 | 28 | 28 |
| D/I Tax Ratio (gen. gov.) | Pearson Correlation | -,174 | 1 | ,405* | ,005 | ,513** | ,071 | ,624** |
| | Sig. (2-tailed) | ,377 | | ,032 | ,981 | ,005 | ,721 | ,000 |
| | N | 28 | 28 | 28 | 28 | 28 | 28 | 28 |
| Population density (/km2) | Pearson Correlation | -,063 | ,405* | 1 | ,159 | ,218 | -,152 | ,501** |
| | Sig. (2-tailed) | ,752 | ,032 | | ,420 | ,264 | ,441 | ,007 |
| | N | 28 | 28 | 28 | 28 | 28 | 28 | 28 |
| Openness (Import+Export)/GDP | Pearson Correlation | -,147 | ,005 | ,159 | 1 | ,255 | -,045 | -,426* |
| | Sig. (2-tailed) | ,455 | ,981 | ,420 | | ,191 | ,821 | ,024 |
| | N | 28 | 28 | 28 | 28 | 28 | 28 | 28 |
| Internet users (/100 people) | Pearson Correlation | -,473* | ,513** | ,218 | ,255 | 1 | ,664** | ,151 |
| | Sig. (2-tailed) | ,011 | ,005 | ,264 | ,191 | | ,000 | ,444 |
| | N | 28 | 28 | 28 | 28 | 28 | 28 | 28 |
| Female labor participation (15+) | Pearson Correlation | -,364 | ,071 | -,152 | -,045 | ,664** | 1 | -,236 |
| | Sig. (2-tailed) | ,057 | ,721 | ,441 | ,821 | ,000 | | ,227 |
| | N | 28 | 28 | 28 | 28 | 28 | 28 | 28 |
| Ln (GDP) | Pearson Correlation | -,029 | ,624** | ,501** | -,426* | ,151 | -,236 | 1 |
| | Sig. (2-tailed) | ,885 | ,000 | ,007 | ,024 | ,444 | ,227 | |
| | N | 28 | 28 | 28 | 28 | 28 | 28 | 28 |

*. Correlation is significant at the 0.05 level (2-tailed).

**. Correlation is significant at the 0.01 level (2-tailed).

# SAŽETAK

Poznato je da država utječe na brojne čimbenike rasta korupcije u poreznom sustavu: primjerice, na porezne propise odnosno njihovu razumljivost, visinu plaća poreznih službenika, sankcioniranje korupcije, transparentnost administracije itd. Problem ovog istraživanja stoga čini pitanje koje je preduvjete potrebno ispuniti u području porezne politike kako bi se pokušao smanjiti nivo korupcije u zemlji. U skladu s time, cilj ovoga istraživanja, s empirijskog stajališta, bio je ispitati utjecaj poreznog sustava na korupciju, i to na uzorku zemalja članica Europske Unije tijekom zadnjeg desetljeća. Aspekti poreznog sustava uključeni u ovo istraživanje bili su **složenost poreznog sustava** te **omjer direktnih i indirektnih poreza**. U svrhu ispunjenja cilja istraživanja, provedena je linearna regresijska analiza.

Linearnom regresijskom analizom utvrđeno je kako se zemlje sa složenijim poreznim sustavima suočavaju s većim razinama korupcije. Također, zemlje koje se više oslanjaju na indirektne poreze pokazale su se korumpiranijima od onih koje se više oslanjaju na direktne poreze.

Budući da su dosadašnja, doduše malobrojna istraživanja sugerirala slabiju vezu složenosti poreznog sustava i korupcije u bogatijim zemljama, ovo saznanje sugerira kako suzbijanje korupcije u razvijenim zemljama ima podjednaku važnost kao i u zemljama u razvoju. Buduća istraživanja o utjecaju raznih ekonomskih i društvenih čimbenika na korupciju trebala bi rezultirati novim metodama borbe protiv ovog upornog i sveprisutnog problema.



**Ključne riječi**: korupcija, složenost poreznog sustava, porezna struktura.

## SUMMARY

It is known that the state influences many factors of corruption in the tax system: for instance, tax regulations and their understandability, wages of tax administrators, penalties on corruption, transparency of administration etc. The question that arises is what prerequisites in the field of fiscal policy are necessary in order to attempt to reduce the level of corruption in a country. Therefore, the aim of this paper, from an empirical standpoint, was to examine the effect of the tax system on corruption in the EU member states, during the recent decade. The aspects of tax system included in this study were tax complexity and tax structure. A linear regression analysis was conducted in order to achieve the aforementioned aims.

Using linear regression analysis, a negative and statistically significant influence of tax complexity on corruption has been affirmed. Also, a negative and significant influence of direct-indirect tax ratio on corruption has been found as well.

Considering that previous, however scarce studies have been suggesting a weaker link between tax complexity and corruption in wealthier countries, these findings lead to a conclusion that the fight against corruption is just as important in developed countries as it is in developing countries. Furthermore, future studies on the influence of various economic and social factors on corruption should result in new methods of fighting this persistent and ubiquitous problem.



**Keywords**: corruption, tax complexity, tax structure.