DJELOVANJE POREZA NA PROMET NEKRETNINA NA TRŽIŠTE NEKRETNINA

Vukojević, Zrinka

Master's thesis / Diplomski rad

2017

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:124:954771

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

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

DJELOVANJE POREZA NA PROMET NEKRETNINA NA TRŽIŠTE NEKRETNINA

Mentor:

prof.dr.sc. Nikša Nikolić

Student:

Zrinka Vukojević

Split, kolovoz, 2017.

SADRŽAJ

1. UVOD 1
1.1. Problem istraživanja 1
1.2. Predmet istraživanja 1
1.3. Ciljevi istraživanja 2
1.4. Istraživačke hipoteze 2
1.5. Metodologija istraživanja 3
1.6. Doprinos istraživanja 3
1.7. Struktura rada 4
2. POREZ NA PROMET NEKRETNINA U POREZNOM SUSTAVU 5
2.1. Što su porezi i zašto ih trebamo plaćati? 5
2.1.1. Druga strana medalje 7
2.1.2. Izazovi pred nositeljima porezne politike u Europi 9
2.2. Osnovni načini oporezivanja 12
2.2.1. Porezi na dohodak 14
2.2.2. Porezi na imovinu 15
2.2.3. Porezi na promet 16
2.3. Porezni trendovi u Europskoj uniji 18
2.4. Porez na promet nekretnina 20
3. TRŽIŠTE NEKRETNINA 23
3.1. Pojam i karakteristike nekretnina i tržišta nekretnina 23
3.2. Značaj tržišta nekretnina za europsko gospodarstvo 25
3.3. Determinante cijena nekretnina 27
3.4.Tržište nekretnina u Hrvatskoj 28
3.5. Utjecaj poreza na promet nekretnina na tržište nekretnina 30
4. EMPIRIJSKO ISTRAŽIVANJE O DJELOVANJU POREZA NA PROMET NEKRETNINA NA TRŽIŠTE NEKRETNINA 32
4.1. Prostorna i vremenska definicija uzorka 32
4.2. Opis korištenih varijabli 34
4.3. Model i metode procjene 37
4.4. Procjena modela 38
4.5. Osvrt na istraživačke hipoteze 41
5. ZAKLJUČAK 42
LITERATURA 43
POPIS SLIKA, GRAFOVA I TABLICA 49
SAŽETAK 50
SUMMARY 50

1. UVOD

1.1. Problem istraživanja

Nekretnine predstavljaju jednu od najvažnijih imovina kako za poduzeća, tako i za pojedince. Naime, s jedne strane u nekretninama se nalaze uredi, trgovine, tvornice, hoteli, wellness centri i različiti zabavni sadržaji, čime je sasvim jasna njihova uloga u poslovnom i društvenom životu. S druge strane nekretnine predstavljaju mjesto kojeg ljudi zovu dom, te je za većinu pojedinaca kupnja nekretnine jedna od najvećih investicija u njihovu životu.

Nekretnine su predmet kupoprodaje na tržištu nekretnina. Tržište nekretnina posebno je tržište s karakteristikama koje ga razlikuju od svih drugih tržišta. Prije svega riječ je o izrazito heterogenom tržištu koje se sastoji od niza geografskih i sektorskih tržišta nekretnina. Stoga, ne može se reći da postoji neko „centralno“ tržište nekretnina, već se može napraviti distinkcija između nekoliko različitih tržišta ovisno o tome koja je vrsta nekretnine koja se kupuje odnosno prodaje.

Najveći značaj tržišta nekretnina proizlazi iz činjenice da je usko povezan s ostalim sektorima u ekonomiji, prije svega sa poslovnim i građevinskim sektorom. Rast potražnje za nekretninama tako može pokrenuti cijeli niz direktnih, indirektnih i induciranih pozitivnih efekata za gospodarstvo. Iz ovog razloga bitno je proučavati tržište nekretnina i što utječe na kretanja na istome.

Većina kretanja na tržištu nekretnina uvjetovana su transakcijskim troškovima. Pored jako visokih cijena samih nekretnina, ovo tržište karakteriziraju i jako visoki transakcijski troškovi koji mogu demotivirati kupnju i tako spriječiti nastanak cijelog niza pozitivnih efekata za gospodarstvo. Porez na promet nekretnina, koji je u fokusu ovog rada, jedan od je transakcijskih troškova vezan uz kupoprodaju nekretnina, a kojeg vlade diljem svijeta nameću s poreznom osnovicom koja čini prodajnu cijenu nekretnine.

1.2. Predmet istraživanja

Na temelju prethodno definiranog problema istraživanja, moguće je definirati predmet istraživanja. Predmet ovog istraživanja je kvantificirati utjecaj kojeg porez na promet nekretnina ima na tržište nekretnina.

1.3. Ciljevi istraživanja

Diplomski rad sastoji se od teorijskog i empirijskog dijela, pa se i ciljevi istraživanja mogu podijeliti na ciljeve teorijske i empirijske prirode. Ciljevi teorijskog dijela rada obuhvaćaju, između ostalih, davanje odgovora i na sljedeća pitanja:

1. Što su porezi i zašto ih trebamo plaćati?
2. Što je porez na promet nekretnina i koja je njegova uloga?
3. Koji su izazovi koji u budućnosti stoje pred nositeljima nacionalnih politika u kontekstu oporezivanja i općenito poreznih sustava?
4. Što postojeći radovi govore o utjecaju poreza na promet nekretnina na tržište nekretnina?

Porez na promet nekretnina u posljednje vrijeme jako je čest, a imajući na umu važnost tržišta nekretnina za gospodarstva diljem svijeta, važno je spoznati empirijske posljedice ovog poreza. Stoga, cilj empirijskog dijela ovog rada jest kvantificirati utjecaj kojeg porez na promet nekretnina ima na tržište nekretnina u odabranim zemljama.

1.4. Istraživačke hipoteze

Nakon što je definiran problem i predmet istraživanja, moguće je formirati istraživačke hipoteze. Glavna hipoteza koja se testira u diplomskom radu glasi:

GH: Porez na promet nekretnina negativno utječe na tržište nekretnina u odabranim europskim zemljama.

Glavna radna hipoteza pretpostavlja negativan utjecaj poreza na promet nekretnina na tržište nekretnina u odabranim europskim zemljama, uvažavajući dosadašnje empirijske radove na ovu temu. Naime, dosadašnja istraživanja provedena na raznim zemljama empirijski su potvrdila negativan utjecaj poreza na promet nekretnina na tržišta nekretnina u istima. Budući da se tržište nekretnina ne može promatrati kroz jedan pokazatelj, odluka o prihvaćanju odnosno neprihvaćanju glavne hipoteze donijeti će se na temelju testiranja pomoćnih istraživačkih hipoteza. U ovom radu testiraju se ukupno tri pomoćne hipoteze koje glase:

PH1: Porez na promet nekretnina negativno utječe na prihod poduzeća u sektoru nekretnina.

PH2: Porez na promet nekretnina negativno utječe na broj zaposlenih u sektoru nekretnina.

PH3: Porez na promet nekretnina negativno utječe na broj poduzeća u sektoru nekretnina.

1.5. Metodologija istraživanja

Rad se sastoji od teorijskog i empirijskog dijela, te su se različite metode koristile pri izradi istih. Teorijski dio rada obuhvaća analizu postojeće znanstvene literature o ovoj problematici, a metode koje su se koristile pritom su (Tkalac et al., 2010):

1. *Metoda deskripcije* - jednostavno opisivanje ili očitavanje činjenica, procesa i predmeta u prirodi i društvu, te njihovog empirijskog potvrđivanja odnosa i veza, ali bez znanstvenog tumačenja i objašnjavanja.
2. *Metoda kompilacije* - preuzimanje rezultata znanstveno-istraživačkog rada, odnosno tuđih opažanja, stavova i zaključaka.
3. *Metoda klasifikacije* – podjela općeg pojma na posebne, u okviru opsega pojma.
4. *Komparativna metoda* – Metoda koja podrazumijeva uspoređivanje činjenica.
5. *Metoda indukcije i dedukcije* - Shvaćanje i donošenje zaključaka o pojedinim dijelovima cjeline na osnovu razumijevanja cjeline, te donošenje zaključaka o cjelini na osnovu razumijevanja pojedinih njenih dijelova.

U empirijskom dijelu rada, a s ciljem testiranja prvotno postavljenih istraživačkih hipoteza, koristila se panel analiza u kojoj su se pored varijabli vezanih za sektor nekretnina (broj poduzeća u sektoru nekretnina, broj zaposlenih i prihod sektora tržišta nekretnina) i poreza na promet nekretnina, koristile i varijable za koje se na temelju dosadašnjih empirijskih istraživanja i ekonomske teorije smatra da također utječu na tržište nekretnina. Riječ je varijablama BDP per capita, inflacija, te domaći krediti odobreni od strane banaka. Odabir zemalja u uzorak baziran je na cluster analizi.

1.6. Doprinos istraživanja

Ne postoji velik broj radova koji su empirijski proučavali utjecaj poreza na promet nekretnina na tržište nekretnina. Prvi takvi radovi datiraju iz 1988. godine. Ovaj rad pridružuje se manjem broju takvih radova. Nadalje, većina ovih radova proučavala je utjecaj poreza na promet nekretnina na tržište nekretnina na jednoj zemlji, dok ovaj rad sadržava analizu utjecaja poreza na promet nekretnina na tržište nekretnina u nekoliko zemalja sličnih strukturnih karakteristika. Konačno, u ovom radu koristi se panel analiza, trenutno jedna od najpopularnijih ekonometrijskih tehnika koja omogućuje istodobnu analizu vremenske i prostorne komponente ekonomskih pojava.

1.7. Struktura rada

Rad se, pored uvodnog, sastoji od još četiri dijela.

Drugi dio rada orijentiran je na poreze i porezne sustave. U ovom dijelu rada prvo je pojmovno određen pojam poreza, te je zatim objašnjeno zbog čega ih moramo plaćati, nakon čega su navedeni izazovi koji u budućnosti stoje pred nositeljima politika u kontekstu oporezivanja. U drugom dijelu rada također su navedeni i objašnjeni oblici oporezivanja koje primjenjuje većina zemalja u svijetu, nakon čega su prezentirati porezni trendovi u Europskoj uniji. Drugi dio diplomskog rada završava detaljnim opisom poreza na promet nekretnina, kao jednog od oblika poreznog opterećenja, koji je u fokusu samog rada.

Treći dio rada orijentiran je na tržište nekretnina. Ovaj dio započinje pregledom glavnih karakteristika promatranog tržišta, te opisom značaja koje ovo tržište ima za gospodarstva zemalja diljem svijeta, kao i opisom glavnih faktora utjecaja na ovo tržište. Nadalje, ovaj dio sadržava pregled najvažnijih trendova na tržištu nekretnina u Hrvatskoj. Treći dio diplomskog rada završava pregledom dosadašnjih empirijskih istraživanja o utjecaju poreza na promet nekretnina na tržište nekretnina.

Četvrti dio diplomskog rada sadrži empirijsko istraživanje. U ovom dijelu prvo je provedena cluster analiza putem koje su se detektirale zemlje Europske unije koje imaju slične strukturne karakteristike s Hrvatskom, te kako bi se formirao uzorak zemalja za provedbu istraživanja. Nadalje, u ovom dijelu potom je opisana korištena metodologija, kao i varijable korištene u panel modelu, nakon čega je provedeno testiranje istraživačkih hipoteza.

Peti dio diplomskog rada posvećen je zaključnim razmatranjima.

2. POREZ NA PROMET NEKRETNINA U POREZNOM SUSTAVU

Porezi su ono što plaćamo za civilizirano društvo.

Sudac Oliver Wendell Holmes[1]

2.1. Što su porezi i zašto ih trebamo plaćati?

Porezi su obvezna davanja koja bez izravne i trenutačne protuusluge država uzima od pojedinaca i poduzeća da bi pomoću prikupljenih novaca financirala javne rashode (Kersen – Škreb i Kuliš, 2010). Pitanje koje se logički nameće jest zašto bi pojedinci i poduzeća plaćali poreze, tim više kada za njihovo plaćanje nema nikakve trenutačne izravne protuusluge?

Najočitiji dio odgovora na ovo pitanje leži u činjenici da država ima moć nametnuti plaćanje poreza, čak i kada pojedinci i poduzeća to ne žele. Naime, država, odnosno javni sektor, jedina raspolaže tzv. pravom *fiskalnog suvereniteta* temeljem kojega može na svom teritoriju, u okviru nacionalnih granica, uvoditi i naplaćivati sve oblike javnih prihoda (Nikolić i Pečarić, 2007).

Drugi, znatno važniji, dio odgovora na postavljeno pitanje krije se u drugom dijelu prethodno navedene definicije poreza, koji navodi kako država iz novaca prikupljenih porezima financira javne rashode. *Javni rashodi* su svi izdaci koje ima država s ciljem zadovoljavanja javnih potreba te su isti, uz poreze koji čine javne prihode, te regulaciju, jedan od tri glavna instrumenta kojima država utječe na privatnu gospodarsku aktivnost. U ove izdatke svakako spadaju socijalni izdaci (mirovine, dječji doplatak, socijalna skrb itd.), subvencije (primjerice poljoprivredi), te izdaci za obranu, školstvo, sudstvo, zdravstvo itd.[2] Sudstvo, javno školstvo, javno zdravstvo, javna sigurnost, nacionalna obrana i sl., nazivaju se *javnim dobrima*, a riječ je o dobrima i uslugama kojima se svi koristimo.

Unatoč činjenici što svi koristimo spomenuta javna dobra, država je ta koja se pojavljuje kao njihov glavni financijer. Razlog tome krije se u karakteristikama javnih dobara, drugačijima od bilo kojeg drugog dobra. Naime, javna dobra karakterizira „*nerivalitet*“, te „*neisključivost*“, što znači da je trošak proširivanja usluge na dodanu osobu jednak nuli, te da je nemoguće isključiti pojedinca iz uživanja usluge (Samuleson i Nordhaus, 2010). Upravo spomenuti nerivalitet, te

[1] Preuzeto iz Samuelson i Nordhaus (2010, str. 312).

[2] Navedeni izdaci u Hrvatskoj klasificiraju se kao tekući izdaci i na iste otpada glavnina svih izdataka. Općenito proračun je podijeljen na niz pozicija i računa kako bi se osigurala transparentnost u smislu da se točno vidi gdje i na što javni novac odlazi. Više u Ott et al., (2003).

vrlo moguća pojava tzv. slobodnih jahača zbog obilježja neisključivosti, demotivira privatni sektor na ulaganja u ovakva dobra i usluge.[3]

Javna dobra jedan su od neuspjeha slobodnog tržišta, prepoznat još od davnih dana. Naime, kako je istaknuo Clarke (1971) slobodno tržište odavno je smatrano inferiornijim u odnosu na državu pri donošenju odluka o raspodjeli resursa koji uključuju javna dobra. Tako su, primjerice, još klasični ekonomisti poput David Hume-a i Adama Smith-a prepoznali potrebu za državnim intervencijama i opskrbom u brojim područjima poput sudstva, školstva, policije, nacionalne obrane i drugih javnih dobara (Cornes i Sandler, 1996). Pored javnih dobara, značajni neuspjesi slobodnog tržišta, zbog kojih je također potrebna državna intervencija u gospodarstvu, su još i *slom nesavršene konkurencije (*primjerice pojava monopola i oligopola*),* kao i *nesavršene informacije* (Samuelson i Nordhaus, 2010).

Iz svega dosada navedenog može se zaključiti kako je uloga države u gospodarstvu prije svega nužna. Međutim, da bi svoju ulogu obavljala, država treba novce. Pritom, **porezi i oporezivanje** su zasada jedini poznati praktični način ubiranja sredstava iz kojih država financira javne rashode (Kesner – Škreb i Kuliš, 2010).

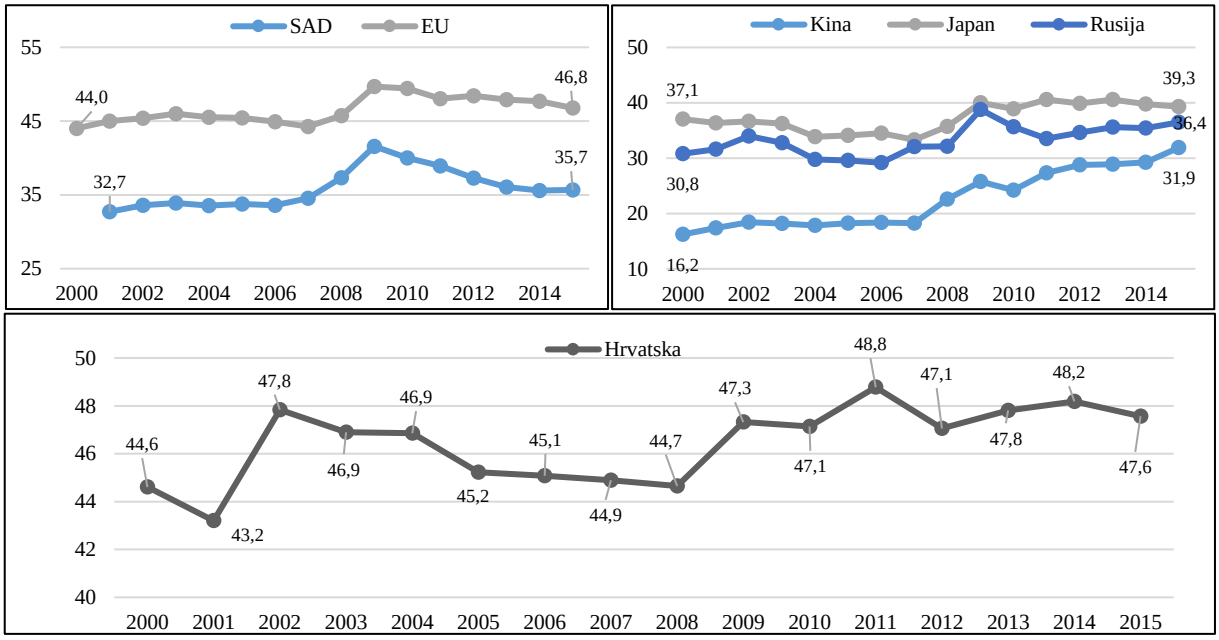
Koliko točno novaca državi treba, ovisi o tome koliko toga u gospodarstvu država i financira. Na globalnoj razini po ovom pitanju značajna je razlika između zemalja, a najčešće se radi usporedba između socijalne Europe (*engl. welfare state*) i ne tako socijalne Amerike. Tako je, primjerice, opće poznato da je sustav socijalne sigurnosti znatno razvijeniji u Europi nego u Americi, što se pak reflektira na veličinu države u gospodarstvu.[4]

Graf 1 prikazuje udio državne potrošnje u BDP-u, odnosno veličinu države, u gospodarstvima svjetskih velesila. Iako se ne može uspoređivati sa svjetskim velesilama, na posebnom dijelu grafa 1 prikazano je i kretanje udjela državne potrošnje u BDP-u za Republiku Hrvatsku. Prvo što se može primijetiti iz grafa 1 jest da je kod svih promatranih zemalja veličina države u zadnjoj promatranoj godini bila veća u odnosu na prvu godinu promatranog razdoblja. Navedeno pak implicira da je prisutan dugoročni trend rasta veličine države kod svih promatranih ekonomija. Iz prvog dijela grafa 1 može se uočiti da je u svim godinama promatranog razdoblja udio državne potrošnje u BDP-u u SAD-u na značajno nižim razinama od udjela zabilježenog u Europskoj uniji, što potvrđuje tezu o „socijalnoj" Europi. Nadalje, iz

[3] Slobodni jahači ili „šverceri" (*engl. free riders*) predstavljaju osobe koje odluče uživati beneficije javnog dobra bez sudjelovanja u plaćanju troškova proizvodnje tih istih beneficija (Udovičić i Mečev, 2011).
[4] Više u Ravnić (1996).

drugog dijela grafa 1 može se učiti i da ostale svjetske velesile, Kina, Rusija i Japan, također imaju manju veličinu države u gospodarstvu u odnosu na zemlje Europske unije.

Hrvatska, kao što je uočljivo iz donjeg dijela grafa 1, ima veći udio državne potrošnje u BDP-u u odnosu na sve svjetske velesile osim EU, gdje se u pojedinim godinama nalazi iznad odnosno ispod prosjeka EU. Konačno, još jedna zanimljivost može se iščitati iz grafa 1. Naime, kod svih promatranih zemalja može se uočiti rapidan rast u veličini države u periodu od 2007. do 2009. godine. Ovaj rast može se pripisati globalnoj financijskoj i gospodarskoj krizi kada je državna intervencija u gospodarstvima zemalja diljem svijeta bila potrebnija nego ikad.



Graf 1: Trendovi u veličini države, svjetske velesile i RH (2000. – 2015.)
Izvor: Izrada autorice na temelju podataka sa Međunarodnog monetarnog fonda (2017).

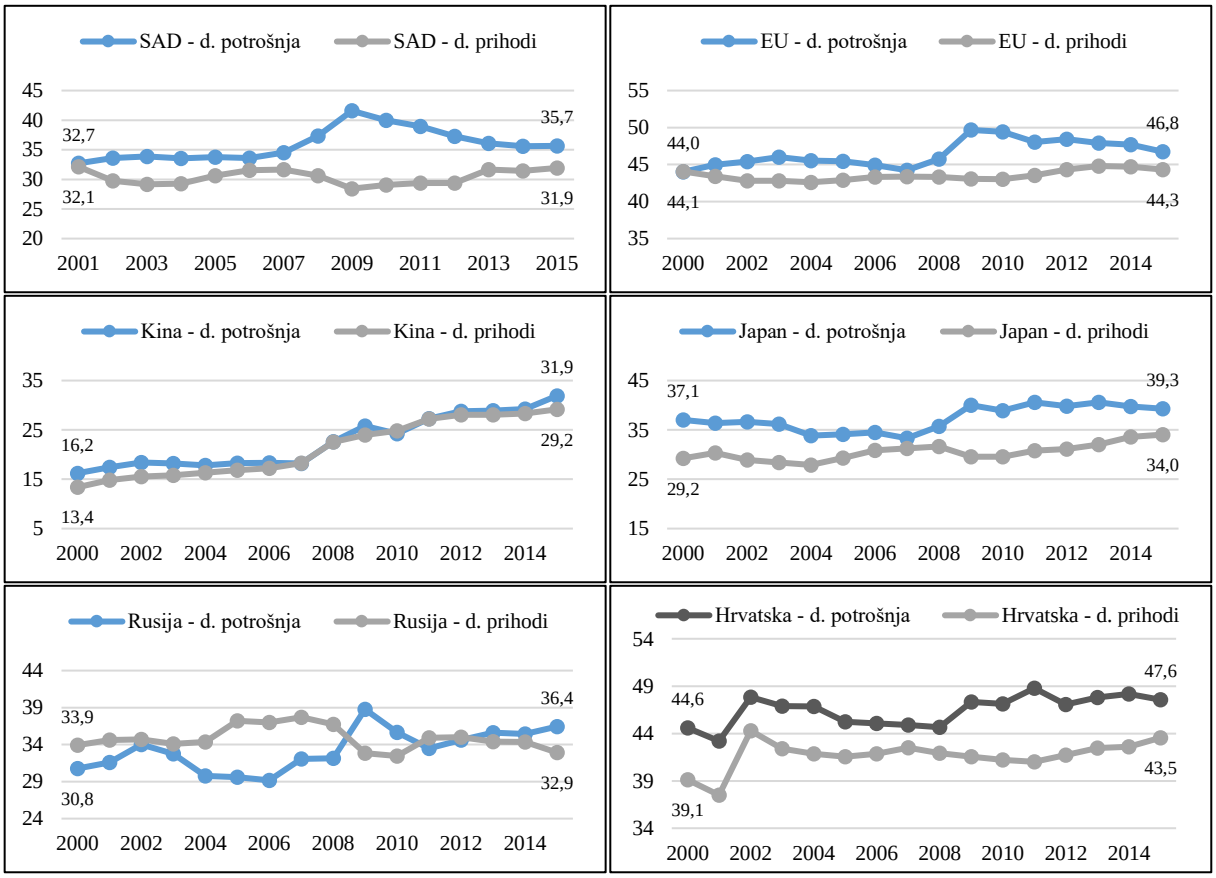
2.1.1. Druga strana medalje

Iz prethodnog dijela shvatljivo je da je uloga države u gospodarstvu nužna, kako zbog nesavršenosti tržišnog mehanizma, tako i u situacijama gospodarskih i financijskih kriza, te da kako bi država mogla obavljati svoju ulogu ona mora prikupljati poreze. Međutim, iako je prikupljanje poreza nužno, te iako država raspolaže pravom fiskalnog suvereniteta, to ne znači da država može nametati poreze do iznemoglosti. Uvijek treba imati na umu da se oporezivanjem oduzima dio nečijeg dohotka i/ili dobiti. Na ovom tragu, već je ranije detektirano kako porezi (naročito njihovo povećanje) mogu negativno utjecati na ekonomski razvoj, i to preko sljedećih mehanizama (Engen i Skinner, 1996):[5]

[5] Preuzeto iz Malešević Perović i Čorić (2013).

1. Porezi mogu destimulirati štednju i investicije, odnosno akumulaciju kapitala.
2. Porezi mogu negativno utjecati na razinu participacije u radnoj snazi i broju radnih sati.
3. Porezi mogu destimulirati akumulaciju znanja i vještina, odnosno ljudskog kapitala.
4. Porezi mogu destimulirati ulaganja u istraživanja i razvoj.
5. Porezi mogu negativno utjecati na marginalnu produktivnost kapitala.
6. Porezi mogu voditi manjoj efikasnosti ljudskog kapitala.

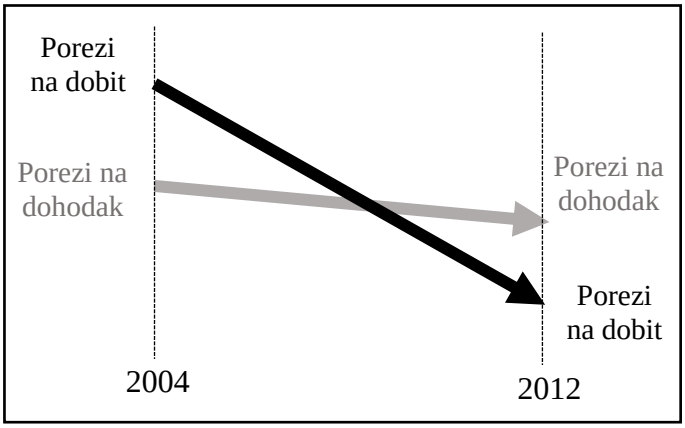
Ako povećanje poreza dovodi do cijelog niza negativnih ekonomskih posljedica, pitanje koje se logički nameće jest što onda napraviti sa konstantno rastućom državnom potrošnjom (Graf 1)? Sljedeći graf prikazuje trendove u udjelu državne potrošnje (veličine države) i državnih prihoda u BDP-u za već ranije promatrane svjetske velesile i Republiku Hrvatsku. Prvo što se može uočiti iz grafa 2 jest da je kod svih promatranih zemalja udio državne potrošnje u BDP-u konstantno veći od udjela državnih prihoda u BDP-u. Drugo, kada je u pitanju udio državnih prihoda u BDP-u, i istom razdoblju kada je zabilježen rapidni rast udjela državne potrošnje u BDP-u (od 2007. do 2009. godine), zabilježen je i pad udjela državnih prihoda u BDP-u, stvarajući u tim kriznim godinama razliku između državnih prihoda i državnih rashoda, veću nego inače.



Graf 2: Udio državne potrošnje i prihoda u BDP-u, svjetske velesile i RH (2000. – 2015.)
Izvor: Izrada autorice na temelju podataka sa Trading Economics (2017a).

Kada su državni rashodi veći od državnih prihoda nastaje deficit državnog proračuna koji se obično zatvara zaduživanjem, što pak rezultira javnim dugom. Logika nalaže da se država ne može vječno zaduživati, te da će u jednom trenutku, prije ili kasnije, doći do povećanja poreznog opterećenja, tim više ako se želi održati socijalna država.

Ovdje se javlja dvojaki problem. S jedne strane, vrlo vjerojatno je negodovanje stanovnika (ujedno i glasača), dok se s druge strane postavlja pitanje koliko povećanje poreza je zaista i moguće. Naime, u posljednje vrijeme svjedoci smo ubrzanih globalizacijskih procesa. Čorić i Malešević Perović (2013) ističu kako je u uvjetima globalizacije visoka mobilnost kapitala, pa je povećana mogućnost alokacije resursa u zemlje s manjim poreznim opterećenjem. Zbog straga od „bijega kapitala" mnoge zemlje mogu se odlučiti ne podizati stope postojećih oblika poreza. Navedeno naročito vrijedi za porez na dobit, gdje je zabilježena čak tendencija njihovog smanjivanja. Naime, prema usporedbi poreznih sustava provedenoj za 189 ekonomija diljem svijeta od strane Svjetske banke, u periodu od 2004. do 2012. godine porezi na dobit padali su ubrzano (Slika 1).



Slika 1: Pad poreza na dobit u 189 zemalja svijeta
Izvor: Prilagodba autorice prema World Bank (2014).

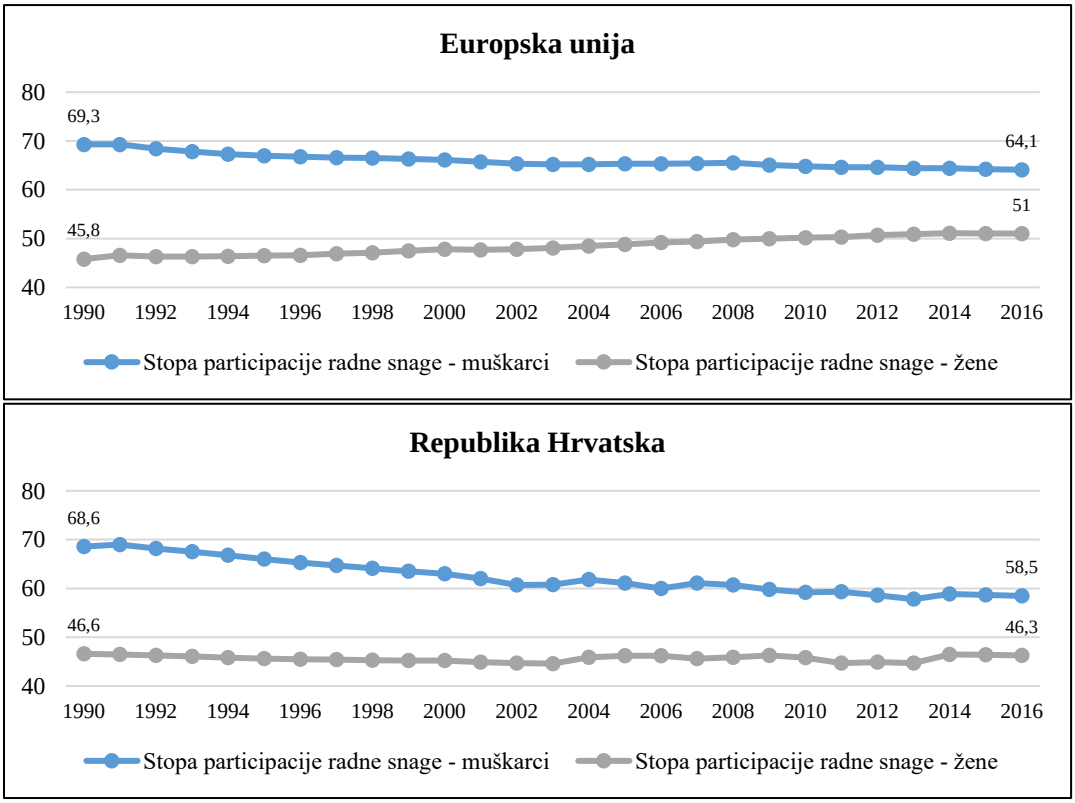
2.1.2. Izazovi pred nositeljima porezne politike u Europi

Dok s jedne strane postoji ozbiljan problem glede mogućnosti podizanja poreznog opterećenja, s druge strane stoji potreba za konstantnim podizanjem državne potrošnje. Stoga je danas, država blagostanja pod velikim upitnikom. Navedeno naročito vrijedi za Europske zemlje koje imaju specifične probleme, a koji svakako postavljaju izazov nositeljima porezne politike. Taylor Gooby (2004) ističe četiri značajna procesa koja su dovela do novih socijalnih rizika koji će uzrokovati probleme u kreaciji budućih poreznih politika u Europi:

1. *rast udjela zaposlenih žena;*

2. *rast udjela starijeg stanovništva;*
3. *promjene na tržištu rada;*
4. *privatizacija.*

Rast udjela zaposlenih žena u ukupno radno sposobnom stanovništvu, uz istovremeni pad udjela zaposlenih muškaraca, prvi je značajan proces koji je doveo do novih socijalnih rizika. Naime, kao što se može vidjeti iz sljedećeg grafa stopa participacije muška radne snage u Europskoj uniji bilježi dugoročni trend pada, sa 69,3% u 1990. godini, na 64,1% u 2016. godini, dok stopa participacije ženske radne snage, u istom periodu ima dugoročni trend rasta, sa 45,8% u 1990. godini na 51% u 2016. godini. Što se tiče Republike Hrvatske, iz drugog dijela grafa 3 može se uočiti da je, u istom periodu, također prisutan dugoročni trend pada stope participacije muške radne snage, koji je k tome i izraženiji od pada zabilježenog u EU, dok je stopa participacije ženske radne snage stabilna na prosječnoj razini od oko 46%.[6]

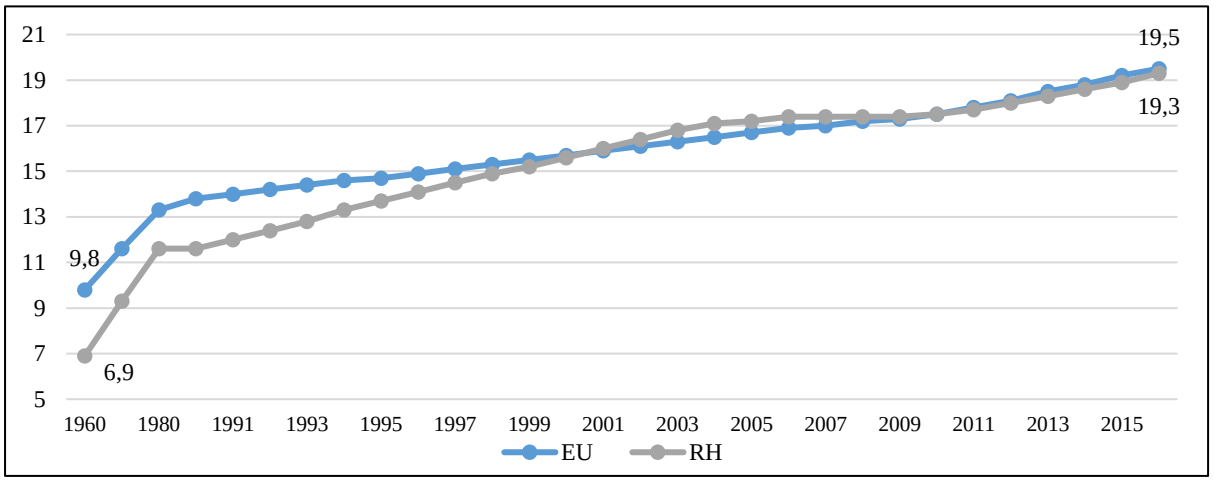


Graf 3: Stopa participacije radne snage u EU i RH, muškarci i žene (1990- - 2016.)
Izvor: Izrada autorice na temelju podataka sa WDI (2017).

Novi socijalni rizici koji se vezuju uz trend prikazan grafom 3 su poteškoće kod žena u balansiranju poslovnog i obiteljskog života, za koje Cantillon et al (2001) ističe da su naročito prisutne u konzervativnim i Mediteranskim zemljama.

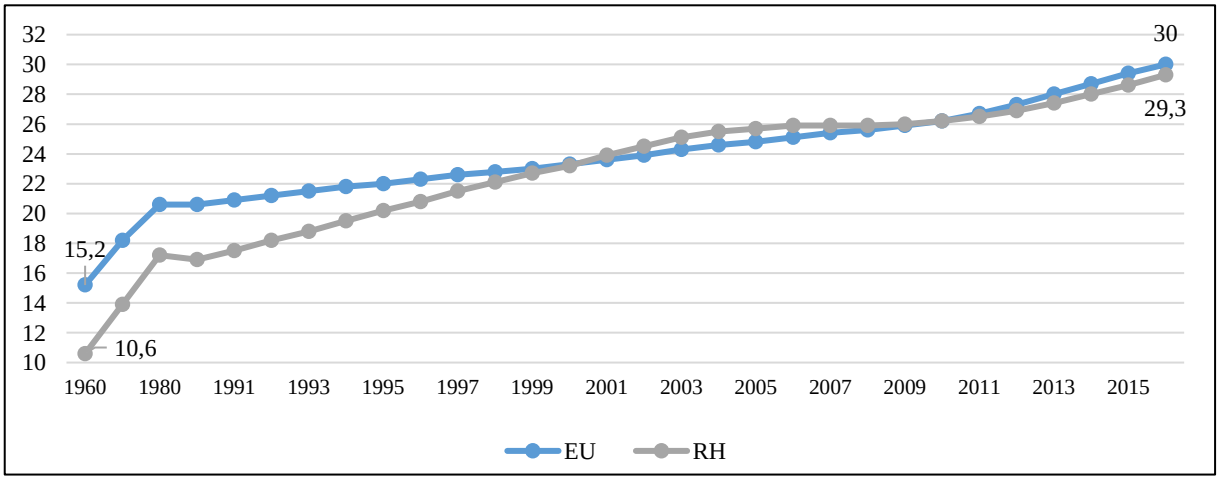
[6] Stopa participacije predstavlja udio radne snage u ukupno radno sposobnom stanovništvu (Bićanić et al., 2009).

Drugi proces, koji je doveo do novih socijalnih rizika, je apsolutni i relativni **porast starijeg stanovništva** koji ima implikacije za tradicionalne troškove države blagostanja poput mirovina i zdravstvenih usluga. Sljedeći graf prikazuje udio stanovništva starog 65 godina i više u ukupnom stanovništvu EU-a i Republike Hrvatske. Može se uočiti konstantan rast ovog udjela iz godine u godinu, kako na razini Unije, tako i kod Republike Hrvatske. Pritom, rast je drastičniji kod Hrvatske, gdje je u 1960. godini bilo svega 6,9% stanovništva starog 65 godina i više, dok je u 2016. godini taj udio narastao na 19,3 posto i bio tek neznatno niži od prosjeka EU.



Graf 4: Populacija stara 65 godina i više, % ukupne populacije, EU i RH (1960 - 2016.)
Izvor: Izrada autorice na temelju podataka sa WDI (2017).

Rast udjela starije populacije nužno je doveo i do rasta stope ovisnog starijeg stanovništva. Kao što se može uočiti iz grafa 5, i u Europskoj Uniji i u Hrvatskoj jasan je trend pogoršanja omjera radno sposobnog stanovništva i stanovništva koje ne radi. Barić i Smolić (2011) naglašavaju da će nastavak ovakvog negativnog trenda dovesti u pitanje održivost financiranja sustava zdravstvene skrbi kakav postoji danas.



Graf 5: Stopa ovisnog starijeg stanovništva, EU i RH (1960- - 2016.)
Izvor: Izrada autorice na temelju podataka sa WDI (2017).

Treći proces, koji uzrokuje nove socijalne troškove, su **promjene na tržištu rada** uzrokovane tehničkim napretkom u proizvodnji, kao i intenziviraju međunarodne konkurencije. Kako ističe Taylor Gooby (2004) prvo je smanjilo udio niskokvalificiranih poslova u industriji, dok je drugo omogućilo zemljama s nižim nadnicama da iskoriste svoju komparativnu prednost.[7]

Konačno, *četvrti proces* koji stvara nove socijalne troškove jest **privatizacija**, nastala prvenstveno u želji „rasterećenja" socijalne države. Iako privatizacija sama po sebi nije socijalni rizik, prebacivanje, primjerice, zdravstva i mirovina na privatni sektor može, kako ističe Taylor Gooby (2004), dovesti do neadekvatnosti i nesigurnosti u istima.

Spomenutim procesima svakako se može dodati i prethodno spomenuta **globalizacija** koja otežava (nužno) povećanje postojećih poreznih opterećenja. Upravo zbog navedenih procesa, u posljednje vrijeme može se uočiti tendencija mijenjanja strukture poreznih sustava. Naime, umjesto da povećavaju pojedine vrste poreza, nositelji politika radije šire poreznu osnovnicu uvođenjem novih poreznih oblika, i to onih koji oporezuju relativno slabo ili nimalo mobilnu imovinu odnosno resurse. Porez na promet nekretnina, koji je u fokusu ovog rada, jedan je od takvih poreza na imobilnu imovinu, a kojeg vlade diljem svijeta nameću s poreznom osnovicom koja čini prodajnu cijenu nekretnine. Dok se porez na promet nekretnina u SAD-u kreće od 0% do 2% u pojedinim saveznim zemljama, u Europi se stope kreću od 4% u Britaniji, preko 5% u Francuskoj, do čak 6-7% u Španjolskoj i Nizozemskoj (Buettner, 2017).[8]

2.2. Osnovni načini oporezivanja

Postoji nekoliko klasifikacija poreza, a najčešće su klasifikacije koje poreze dijele prema (Kesner – Škreb i Kuliš, 2010):

1. *vrsti porezne osnovice;*
2. *razini države vlasti kojoj porezni prihod pripada;*
3. *kategoriji stanovnika koju više opterećuju; te*
4. *onome tko ih zaista i plaća.*

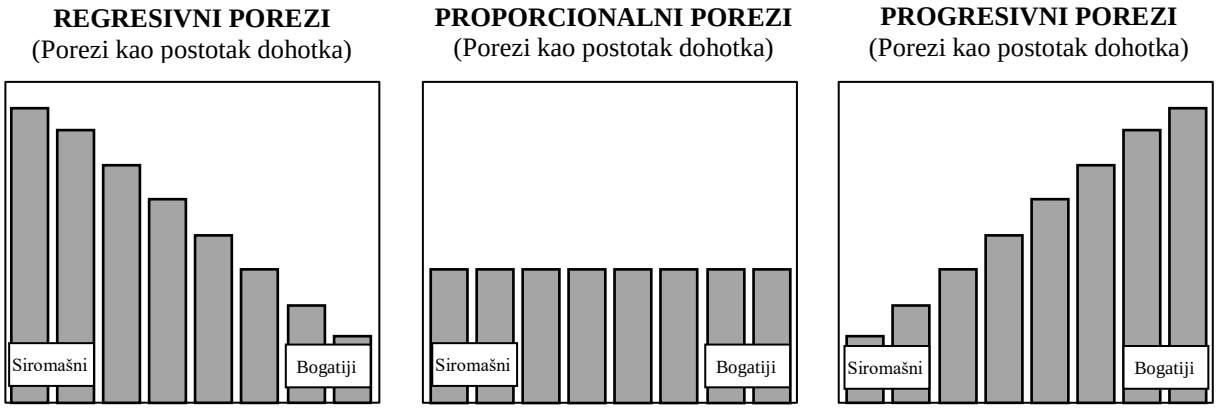
Porezi prema vrsti porezne osnovice, odnosno prema predmetu fiskalnog zahvaćanja, razlikuju se ovisno o tome što se točno oporezuje. Ovdje se može napraviti razlika između poreza na

[7] Najčešće se u ovom kontekstu spominje Kina koja se često optužuje za tzv. socijalni dumping pogotovo od strane SAD-a koji provodi antidamping mjere protiv Kine. Više u Zhongmei (2008).
[8] Više o ovom porezu u točki 2.4. u ovom dijelu.

dohodak, poreza na dobit, poreza na promet, poreza na imovinu, poreza na prihod od imovine, poreza na nasljedstva i darove, poreza na igre na sreću itd. (OECD, 2016).

Prema razini državne vlasti kojoj porezni prihod pripada mogu se razlikovati državni porezi, županijski, te općinski ili gradski porezi. Tako je, primjerice, u RH tipični državni porez, porez na dobit, tipičan županijski porez, porez na cestovna motorna vozila, dok je tipičan gradski ili općinski porez, prirez porezu na dohodak. (NN, 115/16).[9]

Nadalje, jedna od klasifikacija poreza jest ona prema *kategoriji stanovnika koju porezi više opterećuju*. Ova klasifikacija direktno je vezana uz načelo pravednosti, kao jedno od temeljnih poreznih načela, a prema kojem bi bogati trebali platiti više poreza jer imaju i veće mogućnosti plaćanja (ITEP, 2005). Međutim, u praksi, ovo načelo nije uvijek ispunjeno pa se može napraviti distinkcija između regresivnih, proporcionalnih i progresivnih poreza. *Regresivni porezi* uzimaju veći dio dohotka kod obitelji s niskim i srednjim dohotkom u odnosu na obitelji s visokim dohotkom. *Proporcionalni porez*i uzimaju jednak postotak dohotka svima neovisno o visini dohotka, dok *progresivni porezi* veći dio dohotka uzimaju onima s visokim dohotkom (ITEP, 2005). Odnos između navedenih triju vrsta poreza i dohotka, prikazan je slikom 1.



Slika 2: Regresivni, proporcionalni i progresivni porezi
Izvor: Izrada autorice na temelju (ITEP, 2005).

Konačno, porezi se mogu podijeliti ovisno o tome tko ih zaista i plaća. Na ovom tragu mogu se razlikovati izravni i neizravni porezi, gdje su *izravni porezi* oni koje u državu blagajnu uplaćujemo osobno ili ih za nas uplaćuje poslodavac, te se ne mogu prevaliti na drugoga (primjerice porez na dohodak), dok su *neizravni porezi* oni porezi koje osoba(e) uplaćuju u proračun, ali ih zaista ne snose (primjerice porez na dodanu vrijednost).

[9] Naš zakon prepoznaje i kategoriju zajedničkih poreza koji se dijele između spomenutih triju razina vlasti. Porez na promet nekretnina koji je fokusu ovog rada jedan je od zajedničkih poreza. (NN, 115/16).

Ukupan broj poreza koji države primjenjuju jako je velik, a njihove vrste i stope variraju od zemlje do zemlje.[10] U ovom dijelu kratko će se opisati tri osnovna načina oporezivanja koje primjenjuje većima država danas, nakon čega će se detaljno objasniti oblik poreznog opterećenja koji je u fokusu ovog rada, a to je porez na promet nekretnina. Osnovni načini oporezivanja koje primjenjuje većina država danas su:

- porezi na dohodak;
- porezi na imovinu;
- porezi na promet.

2.2.1. Porezi na dohodak

U Republici Hrvatskoj, sukladno Zakonu o porezu na dohodak (NN, 115/16), porezni obveznik poreza na dohodak je fizička osoba koja ostvaruje dohodak od nesamostalnog rada, od samostalne djelatnosti, od imovine i imovinskih prava, od kapitala i/ili dohodak od osiguranja. U drugim zemljama u ovu skupinu poreza ulazi i porez na dohodak trgovačkih društava. Hrvatska porezno-pravna terminologija ne poznaje sintagmu porez na dohodak trgovačkog društva, nego se koristi izrazom *porez na dobit* (Kesner – Škreb, 2004).

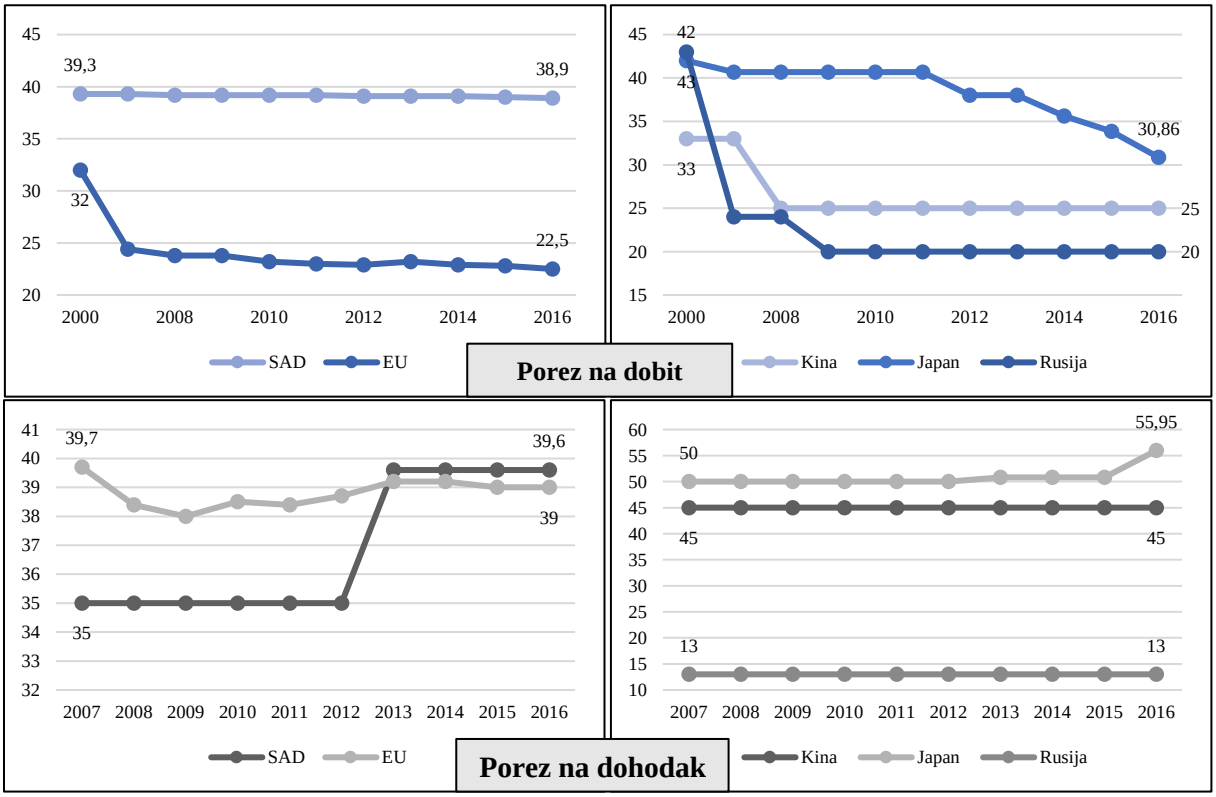
Porez na dohodak može biti, te obično i jest, najpravedniji izvor državnih prihoda. Naime, kod prikupljanja ove vrste državnog prihoda najčešće se osigurava da bogatiji porezni obveznici plaćaju i više poreza. Tako, primjerice, Samuelson i Nordhaus (2011) ističu kako je porez na dohodak pojedinaca u SAD-u progresivan što znači da ljudi s višim dohocima plaćaju poreze po višoj prosječnoj stopi od onih s nižim dohocima. Ista je situacija i u Republici Hrvatskoj. Naime, prema Zakonu o porezu na dohodak (NN, 115/16) dohodak se oporezuje po stopama od 24% i 36% ovisno o visini porezne osnovnice.[11]

Porezi na dohodak čine jako velik dio ukupnih državnih prihoda međutim, iako poštuju porezno načelo pravednosti te promiču ekonomsku jednakost, mnogi ekonomisti predlažu reforme poreznog sustava u kojima se dohodak uopće ne bi oporezivao.[12] Najveći problem ovog poreza predstavlja postojanje jako velikog broja olakšica i izuzetaka od oporezivanja, što ga čini kompliciranim, ali i podložnim za poreznu evaziju.

[10] Primjerice u SAD-u postoji čak 97 različitih vrsta poreza koje Amerikanci plaćaju svake godine. Više u Snyder (2014).
[11] Ranijih godina postojale su 3 porezne stope za porez na dohodak i to porezne stope od 12%, 25% i 40%.
[12] Ovakvi autori obično predlažu potpuno oporezivanje potrošnje, eliminiranje svih olakšica i sl. Više u Hall i Rabushka (2007).

Sljedeći grafikon prezentira kretanje stopa poreza na dobit i poreza na dohodak najvećih svjetskih velesila. Iz grafa je uočljivo da su kod svih promatranih zemalja, u promatranom desetogodišnjem razdoblju stope poreza na dobit smanjile se. Pritom, najveći pad stopa poreza na dobit zabilježen je u Rusiji zatim Japanu, EU i u Kini, dok je najmanji pad stopa poreza na dobit zabilježen u SAD-u. Ovako smanjenje stopa poreza na dobit ide u prilog tezi o utjecaju globalizacije na odluke vezane uz oporezivanje visoko mobilnih resursa.

Na donjem dijelu grafa 6, prezentirano je kretanje stopa poreza na dohodak. Uočljivo je da je kod svih promatranih zemalja prisutan ili rast stopa poreza na dohodak (EU, Japan), ili su kroz cijelo promatrano razdoblje ostale na istoj razini (Kina, Rusija).



Graf 6: Stope poreza na dobit i poreza na dohodak, svjetske velesile (2000/2007. – 2016.)
Izvor: Izrada autorice sa Trading Economics (2017b).

2.2.2. Porezi na imovinu

Porez na imovinu nameće se isključivo na nekretnine – zemlju i građevine. Za razliku od poreza na dohodak koji predstavljaju poreze na tijek, ovaj porez predstavlja porez na stanje ili fond (Kesner – Škreb, 2002). Također, u odnosu na ostale vrste poreza, ovi porezi uglavnom su prihod proračuna lokalnih jedinica.

Kao i kod ostalih oblika poreza, tako se i ovom obliku oporezivanja mogu pronaći prednosti i mane. Činjenica jest da je riječ o jako „zgodnom“ izvoru prihoda za lokalne vlasti budući da je njegovo plaćanje praktički nemoguće izbjeći. Naime, nekretnine se ne mogu kao kapital prenijeti tamo gdje je porez niži ili ga uopće nema. Također, promatrajući s aspekta ekonomske jednakosti, ovaj porez trebao bi biti poželjan jer stavlja veće opterećenje na bogatiji sloj stanovništva. S druge strane, potencijalno negativni efekt ovog poreza je destimuliranje štednje što pak negativno utječe na ekonomski razvoj (Čorić i Malešević Perović, 2013).

2.2.3. Porezi na promet

Porez na promet, zajedno s trošarinama kao njihovim posebnim oblikom, čini važan dio ukupnih poreznih prihoda diljem država. Riječ je o najpoznatijoj vrsti poreza na potrošnju gdje se porez, umjesto na dohodak, plaća na kupnju dobara i usluga (Samuelson i Nordhaus, 2010). Imajući to na umu, sasvim je jasno da ovaj porez plaća svatko, skoro svaki dan.

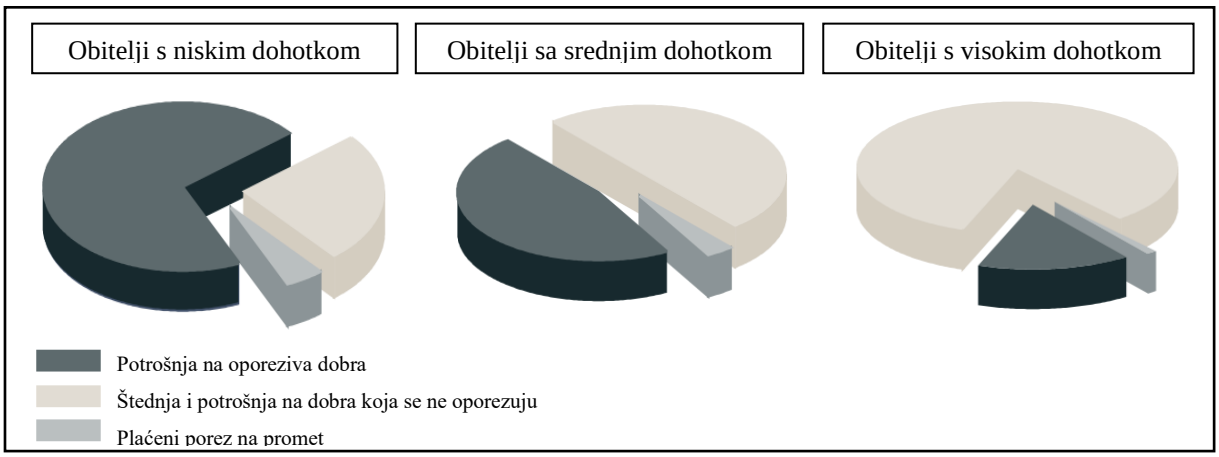
Porez na promet propisuje se postotkom na cijenu dobra koje se razmjenjuje, a najveća prednost mu je lakoća prikupljanja. Naime, porez na promet, iako ga plaća kupac, prikuplja prodavač dobra odnosno usluge kao postotak prodajne cijene, čime je jasno da je riječ o neizravnom porezu.[13] Pritom, da bi ubrala ovu vrstu poreza, porezna vlast ne treba raspolagati brojim podacima kao što je to slučaj kod, primjerice, oporezivanja dohotka (Kesner – Škreb, 2005).

Kao i kod prethodnih načina oporezivanja, tako se i ovom načinu oporezivanja mogu pronaći prednosti i mane. Najvećom prednošću ovog poreza autori smatraju „ako ne želiš platiti porez, nemoj kupiti“. Ovo možda i ima nekog smisla ako su ona najnužnija dobra oslobođena plaćanja poreza poput, primjerice, hrane, odjeće, režija, stanarine i medicinskih potrepština. Na ovaj način svakako će biti manji porezni pritisak na one s manjim dohocima. Međutim, dok u, primjerice, Republici Hrvatskoj ima ovakvih izuzetaka u SAD-u, kako ističe Farnsworth (2011) ovakvi izuzeci u pojedinim saveznim zemljama ne postoje čime su oni s nižim dohocima znatno ugroženi.

Najvećom manom poreza na promet smatra se njegov regresivni učinak budući da uzima veći postotak dohotka siromašnijima nego bogatijima (Samuelson i Nordhaus, 2010). Naime, kako ističe Farnsworth (2011) porezi na promet nisu determinirani dohotkom, a čak i oni najsiromašniji moraju konzumirati određeni broj dobara i usluga, te platiti odgovarajući iznos

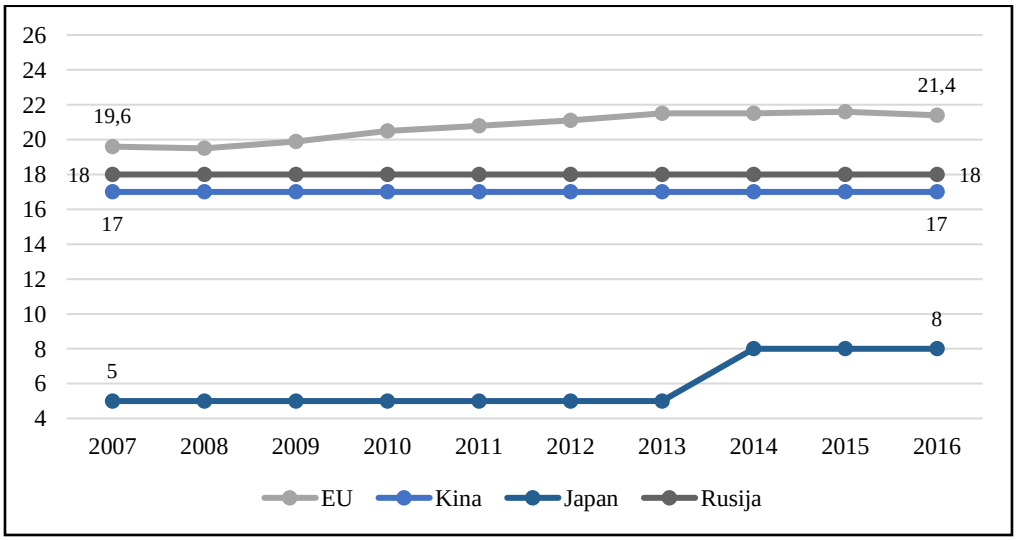
[13] Lakoća prikupljanja odnosi se na državu. Samim prodavačima zasigurno predstavlja gnjavažu, te se promatrano s aspekata poduzeća ovo smatra njegovim nedostatkom (ITEP,2011).

poreza na promet. Na ovom tragu, zabrinjavajuća je procjena Instituta za oporezivanje i ekonomsku politiku, bazirana na potrošačkoj anketi, prema kojoj obitelji s niskim dohotkom troše čak tri četvrtine svog dohotka na proizvode koji se oporezuju porezom na promet, obitelji sa srednjim dohotkom oko pola svog dohotka, dok najbogatije obitelji troše tek šestinu svog dohotka na proizvode koji se oporezuju porezom na promet (ITEP, 2011). Grafički prikaz njihove procjene predstavljen je Slikom 1.



Slika 3: Utjecaj poreza na promet pri različitim razinama dohotka
Izvor: Prilagodba autorice na temelju ITEP (2011).

Sljedeći grad prikazuje kretanje stopa poreza na promet kod svjetskih velesila. Može se uočiti da je jedino u Europskoj uniji prisutan rast ovih poreza, koji su s prosječne razine od 19,6% u 2007. godini porasli na 21,4 % na razini Unije u 2014. godini. U Rusiji i Kini ovi porezi su u cijelom promatranom razdoblju na istoj razini, dok je u Japanu zabilježen rast tek iza 2013. godine.



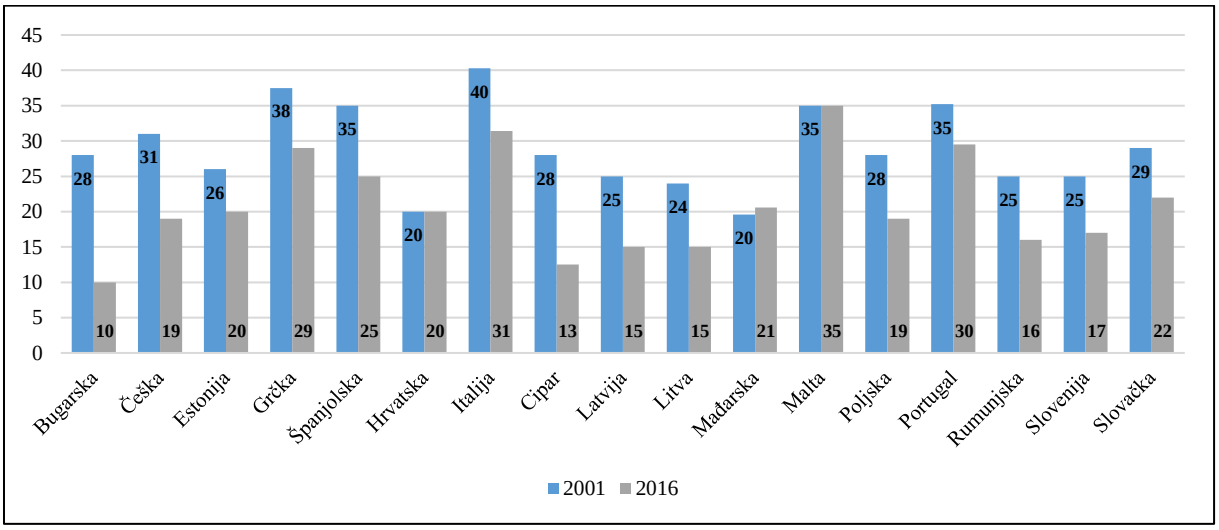
Graf 7: Stope poreza na promet, svjetske velesile (2007. – 2016.)
Izvor: Izrada autorice sa Trading Economics (2017c).

2.3. Porezni trendovi u Europskoj uniji

Europska unija je područje s visokim poreznim stopama. Naime, kao što se moglo uočiti još na grafu 2 u prvom potpoglavlju ovog dijela, udio poreznih prihoda EU u BDP-u u 2015. godini iznosio je 44,3% što je za čak 12,4 postotna poena više u odnosu na udio poreznih prihoda u BDP-u zabilježen u SAD-u, u istoj godini. Također, ovaj udio u Uniji ima i tendenciju rasta.

Kako navode iz Europske komisije, struktura poreza značajno varira od zemlje do zemlje, te obično nove zemlje članice imaju drugačiju strukturu u usporedbi sa starijim članicama Europska komisija (2016). Ipak, proučavanjem dužih vremenskih serija mogu se uočiti neke zajedničke karakteristike kod članica, kada je u pitanju oporezivanje.

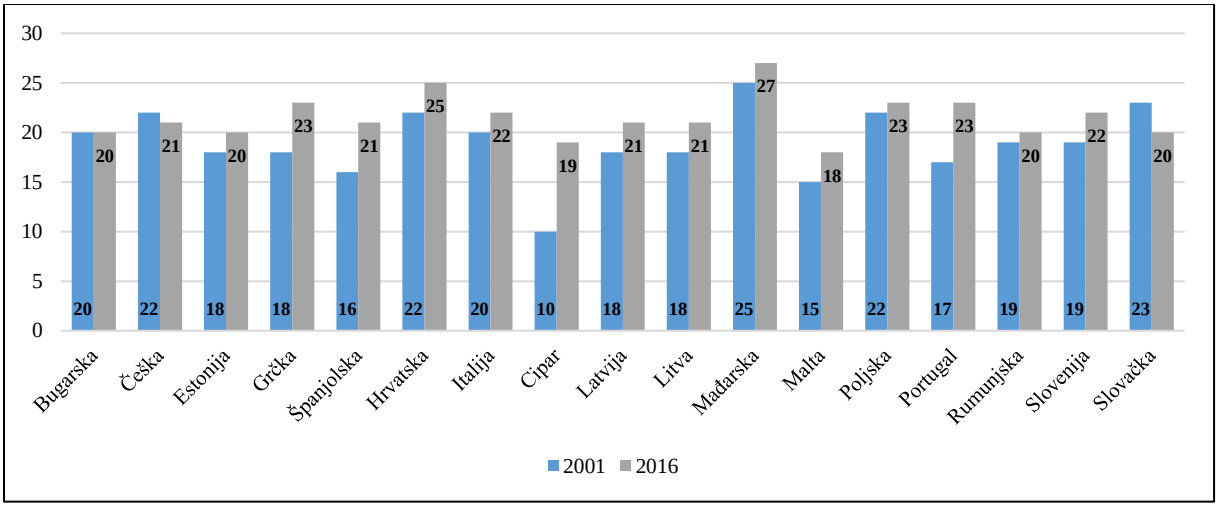
Sljedeći graf prikazuje stope poreza na dobit u odabranim zemljama Europske unije, u 2001. i 2016. godini.[14] Može se primijetiti da je u svim promatranim zemljama, izuzev Hrvatske, Mađarske i Malte, stopa poreza na dobit bila **značajno niža** u 2016., u odnosu na 2001. godinu. Pritom, najveći pad zabilježile su Bugarska, u kojoj se stopa smanjila za čak 18 postotnih poena, i Cipar, gdje se stopa poreza na dobit smanjila za 15,5 postotnih poena. Ovakva kretanja u skladu su s tezom o smanjivanju oporezivanja visoko mobilnog kapitala. Kada je u pitanju Republika Hrvatska, iz grafa 8 može se uočiti da je zadržana stopa od 20%, dok se kod Mađarske stopa poreza na dobit povećala za jedan postotni poen.[15]



Graf 8: Stope poreza na dobit u Europskoj uniji (2001. i 2016. godina)
Izvor: Izrada autorice na temelju podataka iz Europska komisija (2016).

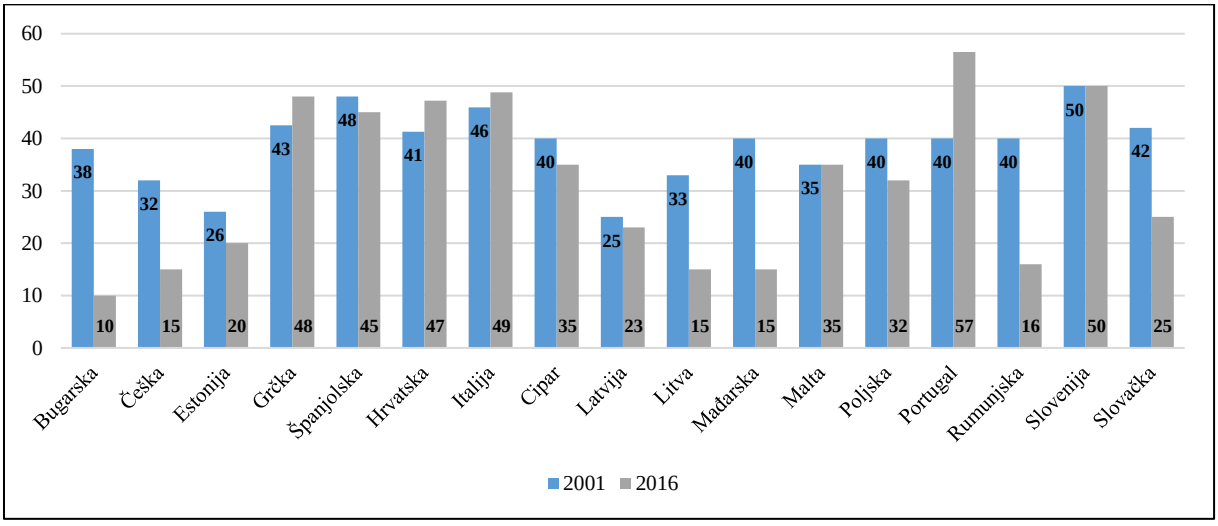
[14] Odabrane su zemlje Europske unije nad kojima se provelo i istraživanje u empirijskom dijelu ovog rada.
[15] Valja napomenuti da je u 2017. godini, i u Hrvatskoj došlo do smanjena stope poreza na dobit, i to sa 20 na 18% za poduzeća koja ostvaraju više od 3 mil. kuna prihoda godišnje, odnosno na 12% za poduzeća koja godišnje ostvaruju do 3 mil. kuna prihoda (NN, br. 115/16).

Kada je u pitanju porez na potrošnju, i to konkretno PDV, kod promatranih europskih zemalja, mogu se uočiti potpuno suprotni trendovi. Naime, u 2016. u odnosu na 2001. godinu, stopa poreza na dodanu vrijednost kod svih zemalja, izuzev Bugarske, Češke i Slovačke, bila je (značajno) **viša**. Pritom, najveći rast zabilježen je na Cipru, gdje je stopa poreza na dodanu vrijednost porasla s 10% u 2001. na 19% u 2016. godini, zatim Portugalu gdje je stopa poreza na dodanu vrijednost porasla sa 17% na 23% u istom razdoblju.



Graf 9: Stope PDV-a u Europskoj uniji (2001. i 2016. godina)
Izvor: Izrada autorice na temelju podataka iz Europska komisija (2016).

Mješovite informacije pruža kretanje stopa poreza na dohodak. Naime, kao što je uočljivo iz sljedećeg grafičkog prikaza, stope poreza na dohodak u nekim zemljama bile su više, a u nekima niže, u 2016. u odnosu na 2011. godinu. Tako je, primjerice, najveći rast zabilježen kod Portugala (rast za 17 p.p.), dok je najveći pad zabilježen kod Bugarske (pad za 28 p.p.).



Graf 10: Stope poreza na dohodak u Europskoj uniji (2001. i 2016. godina)
Izvor: Izrada autorice na temelju podataka iz Europska komisija (2016).

2.4. Porez na promet nekretnina

Porez na promet nekretnina spada u skupinu imovinskih poreza (*engl. Tax on immovable property*), te se vezuje uz nekretnine kao specifični oblik imovine. Ovaj porez važno je razlikovati od poreza na nekretnine. Naime, porez na nekretnine plaća se svake godine, dok se porez na promet nekretnina plaća jednokratno, prilikom kupoprodaje nekretnine.

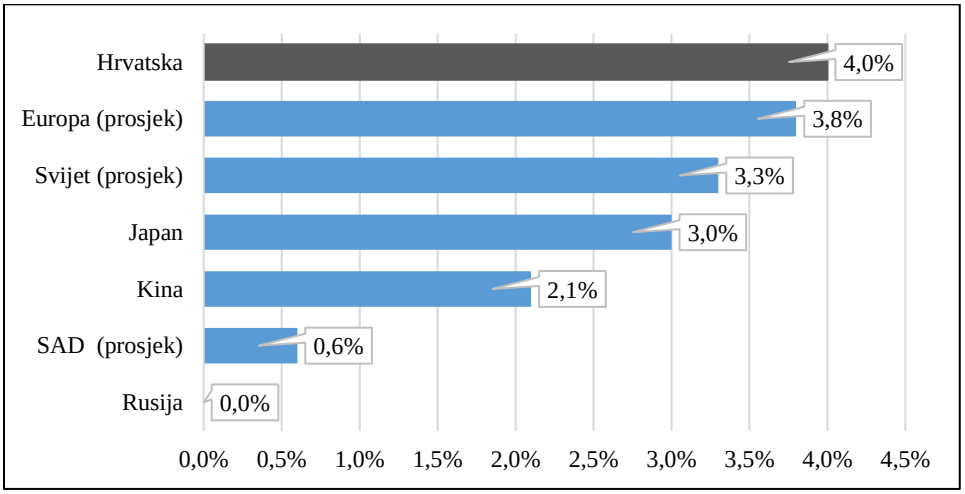
Vlade diljem svijeta nameću porez na promet nekretnina s poreznom osnovicom koja čini prodajnu cijenu nekretnine. Dok se porez na promet nekretnina u SAD-u kreće od 0 do 2% u pojedinim saveznim zemljama, u Europi se stope kreću od 4% u Britaniji, preko 5% u Francuskoj i Njemačkoj, do čak 6-7% u Španjolskoj i Nizozemskoj (Buettner, 2017).

Nepostojeće odnosno značajno niže stope poreza na promet nekretnina u SAD-u, u odnosu na značajno više stope u Europi direktno se mogu povezati sa karakteristikama socijalne države i prisutnim globalizacijskim trendovima. Naime, opće je poznato da vlada SAD-a financira mnogo manje javnih dobara u odnosu na Europu. Stoga su europskim zemljama potrebni i veći državni prihodi. Nadalje, zbog sve veće otvorenosti i povezanosti između zemalja, i mogućnosti internacionalizacije poslovanja, mnogo država okreće se oporezivanju manje pokretne imovine poput nekretnina, uz zadržavanje postojeće razine ili smanjivanje stopa kod ostalih oblika oporezivanja. Grafovi vezani za europske zemlje, prezentirani u prethodnom dijelu, potvrđuju ove navode.

U Republici Hrvatskoj oporezivanje prometa nekretnina uređeno je Zakonom o porezu na promet nekretnina (NN, 115/16) i Zakonom o porezu na dodanu vrijednost (NN, 115/16). Prema najnovijoj izmjeni Zakona o porezu na promet nekretnina, stopa poreza na promet nekretnina iznosi 4%, te predstavlja smanjenje za jedan postotni bod u odnosu na ranija razdoblja. Međutim, važno je naglasiti da ova stopa vrijedi u slučaju kupoprodaje nekretnina između dvije fizičke osobe koje nisu obveznici PDV-a. Ako je kojim slučajem riječ o kupnji nekretnine izgrađene iza 1997. godine, a od pravne osobe, promet nekretnina oporeziva se po stopi koju uređuje Zakon o porezu na dodanu vrijednost. Trenutno stopa poreza na dodanu vrijednost u Hrvatskoj iznosi 25%, što upućuje na strahovito visoke transakcijske troškove s kojima se suočava kupac.

Sljedeći graf prezentira stope poreza na promet nekretnina u nekoliko svjetskih velesila i u Republici Hrvatskoj. Može se uočiti da je stopa poreza na promet nekretnina u Hrvatskoj veća nego u bilo kojoj svjetskoj velesili, te da je veća i od prosjeka Europske unije. Nadalje, Europska

unija u čijem sastavu je i Hrvatska ima veću prosječnu stopu poreza na promet nekretnina u odnosu na svjetski prosjek, te značajno veću stopu u odnosu na SAD. Iz grafa 11 je također uočljivo da u Rusiji uopće ne postoji ovaj oblik poreznog opterećenja.



Graf 11: Stopa poreza na promet nekretnina, svjetske sile i RH (2017)
Napomena: stopa primjenjiva na kupnju nekretnine u vrijednosti od milijun dolara.
Izvor: Izrada autorice na temelju podataka iz Maeremans (2017).

U postojećoj literaturi koja se bavi ovom tematikom, uglavnom prevladava negativan stav o porezu na promet nekretnina.[16] Tako, primjerice, Filipić (2007) tvrdi kako porez na promet nekretnina predstavlja prepreku mobilnosti radne snage jer demotivira pojedince na kupnju. Ovaj problem postaje još izraženiji ako cijene stanova rastu, jer onda automatski raste i iznos kojeg kupac plaća na ime poreza na promet nekretnina. Spomenuta tvrdnja još je ranije i empirijski potvrđena na primjeru Nizozemske gdje su Van Ommeren i Van Leuvensteijn (2003) pokazali da povećanje transakcijskog troška za 1%, mjereno kao postotak vrijednosti nekretnine, smanjuje mobilnost stanovnika za najmanje 8%.

Kukić i Švaljek (2012) navode tri glavna nedostatka poreza na promet nekretnina:

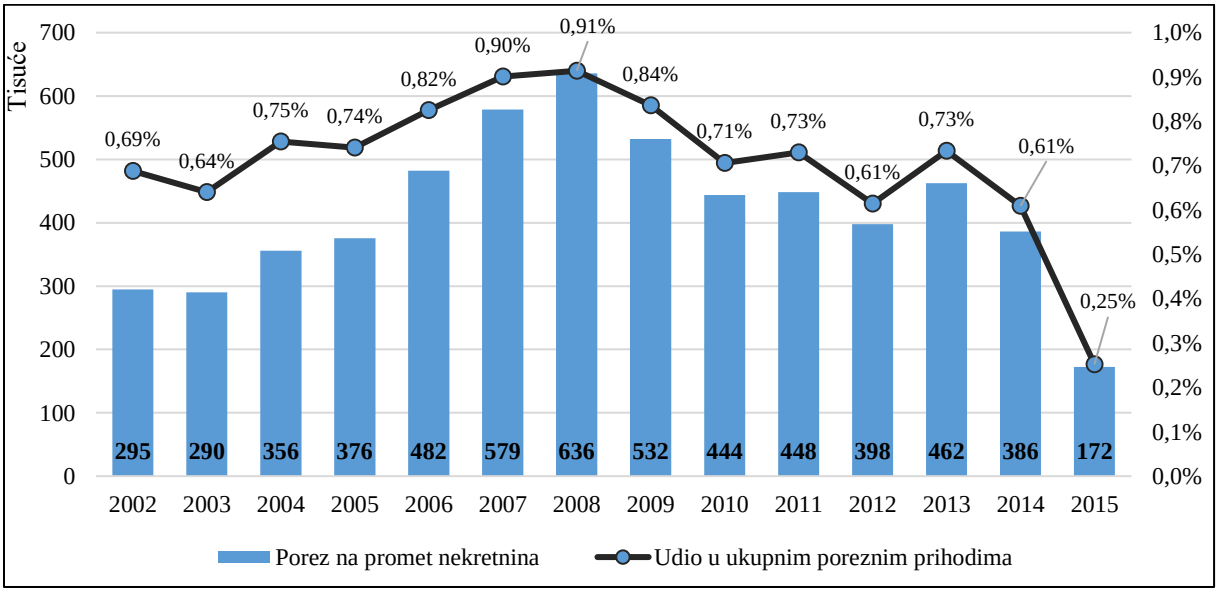
1. porez na promet nekretnina neopravdano kažnjava one koji češće kupuju i prodaju nekretnine, odnosno pridonosi držanju nekretnina;
2. kupci mogu izbjeći upis vlasništva u zemljišne knjige kako bi izbjegli i plaćanje poreza, što dovodi do neuređenosti zemljišnih evidencija;

[16] U ovom dijelu navedeni su utjecaji poreza na promet nekretnina na razne ekonomske varijable izuzev njegova utjecaja na tržište nekretnina. Utjecaj poreza na promet nekretnina na tržište nekretnina dan je zasebno i nalazi se u četvrtom potpoglavlju trećeg dijela ovog rada.

3. prihodi od poreza na promet nekretnina ovise o vrijednosti nekretnina koje su predmet transakcije i samom broju transakcija, pa su podložni većim cikličkim oscilacijama.

S obzirom da je jako nestabilan izvor prihoda proračuna, porez na promet nekretnina čini tek manji dio ukupnih poreznih prihoda, te predstavlja prihod kojim uglavnom raspolažu lokalne jedinice.[17]

Sljedeći graf prikazuje iznos prikupljenog poreza na promet nekretnina u Hrvatskoj u periodu od 2002. do 2015. godine, te njegov udio u ukupnim poreznim prihodima u istom periodu. Može se uočiti da je udio ovog poreza u ukupnim poreznim prihodima zaista zanemariv, te da u nijednoj godini nije prešao 1%. Nadalje, od 2009. godine prisutno je konstantno smanjenje ovog poreza kako u apsolutnim, tako i u relativnim terminima, da bi u 2015. godini prihod od ovog poreza bio manji nego ikad (172 tisuće kuna odnosno 0,25% ukupnih poreznih prihoda).



Graf 12: Porez na promet nekretnina i udio u ukupnim poreznim prihodima ('02.-'15.)
Izvor: Izrada autorice na temelju podataka sa Ministarstva financija.

Imajući na umu ovako mali prihod od poreza na promet nekretnina, a istovremeno jako velike (potencijalne) negativne posljedice koje se vezuju uz ovaj porez, zaista je upitna nužnost postojanja ovog poreznog opterećenja u državama.

[17] U Hrvatskoj 60% ovog poreza ide jedinicama lokalne uprave, dok 40% ide državnoj upravi.

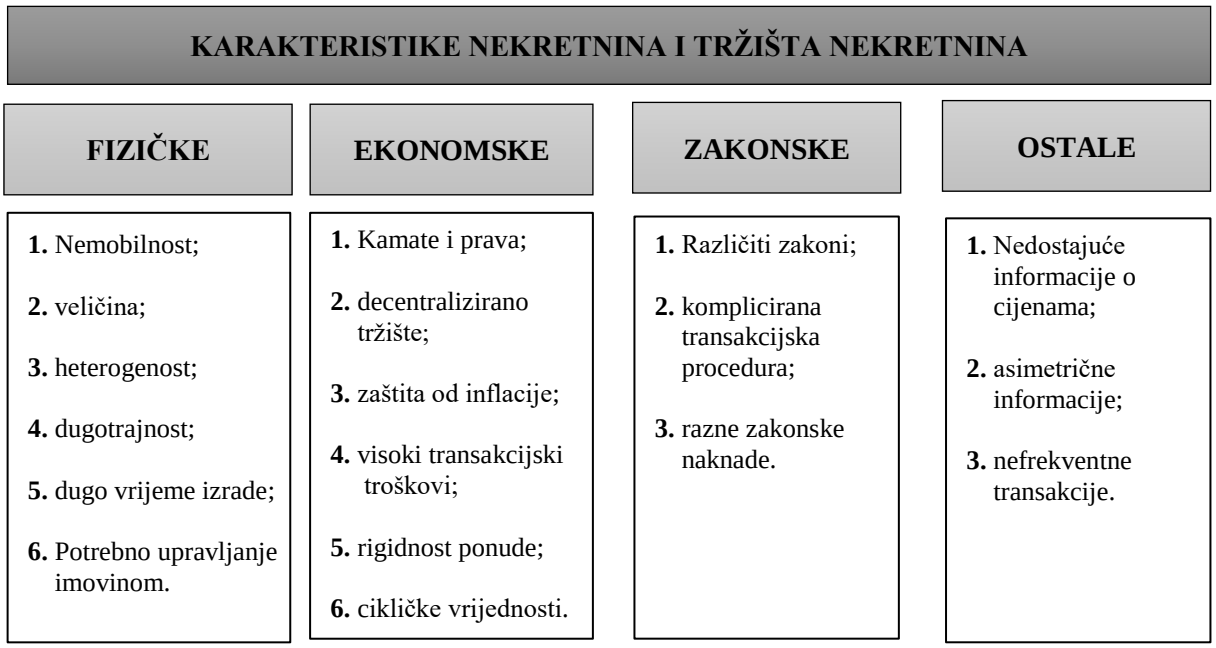
3. TRŽIŠTE NEKRETNINA

3.1. Pojam i karakteristike nekretnina i tržišta nekretnina

Nekretnina je jedna od najvažnijih nefinancijskih imovina, čija se ekonomska uloga mijenja ovisno o tome tko je vlasnik iste i tko je koristi. Na ovom tragu mogu se razlikovati tri vrste entiteta koji posjeduju i koriste nekretninu (Shimizu, 2014):

1. *kućanstva* koja nekretnine koriste u stambene svrhe;
2. *poduzeća* koja nekretnine koriste za proizvodnju dobara i usluga;
3. *vlade* koje nekretnine koriste za pružanje javnih usluga.

Tržište nekretnina, kao i bilo koje drugo tržište, predstavlja mjesto susreta ponude i potražnje. Pritom, na strani ponude nalaze se svi oni koji nude određenu nekretninu pri određenoj cijeni, dok se na strani potražnje nalaze svi oni koji potražuju određenu nekretninu. Ipak, tržište nekretnina posebno je tržište s karakteristikama koje ga razlikuju od svih drugih tržišta. Prije svega, tržište nekretnina nije jedno tržište odnosno ne predstavlja jedno mjesto na kojem se vrši kupoprodaja nekretnina. Naime, tržište nekretnina sastoji se od cijelog niza geografskih i sektorskih pod-tržišta. Sve karakteristike nekretnina i tržišta nekretnina po kojima se ovo tržište razlikuje od svih ostalih vrsta tržišta, mogu se podijeliti u četiri skupine: fizičke, ekonomske, zakonske, te ostale karakteristike tržišta nekretnina (Slika 4).



Slika 4: Karakteristike tržišta nekretnina
Izvor: Izrada autorice na temelju: Appraisal Institute (1987); Hilbers et al (2001); Klimczak (2010): Kolarek, (2014) i Learn Mortgage (2017).

Najočitije specifičnosti tržišta nekretnina proizlaze iz same prirode nekretnina koje su predmet kupoprodaje na tržištu nekretnina. Naime, nekretnine predstavljaju *opipljivu* i *nepokretnu imovinu* koja uključuje zemljište, stvari koje su prirodni dio zemljišta (stabla, minerali i sl.), kao i sve objekte koji su pridruženi zemljištu, od zgrada do trajnih građevnih elemenata (Appraisal Institute, 1987).

Druga bitna fizička karakteristika tržišta nekretnina jest njegova *heterogenost* koja se očituje u nepostojanju dviju potpuno jednakih nekretnina s istim objektivnim (fizičkim) i subjektivnim obilježjima, koji u većoj ili manjoj mjeri utječu na samu vrijednost nekretnine (Kolarek, 2014). Naime, na tržištu nekretnina svaka nekretnina ima unikatna obilježja od lokacije do dizajna. Tako se, primjerice, čak i dvije potpuno iste nekretnine, u smislu da su na isti način dizajnirane i rađene od istih materijala, ne smatraju istima prvenstveno zbog lokacije.

Hilbers et al (2001) navode još četiri karakteristike koje tržište nekretnina razlikuje od bilo kojeg drugog tržišta, a koje proizlaze iz, prethodno spomenutih, karakteristika nemobilnosti i heterogenosti. To su:

1. *nefrekventne transakcije;*
2. *rigidna ponuda;*
3. *cjenovni pregovori; te*
4. *visoki transakcijski troškovi.*

Ukratko objašnjeno, *nefrekventne transakcije* odnose se na činjenicu da se kupoprodaja nekretnina ne obavlja svaki dan. Naime, zbog visokih troškova povezanih s istom, većina ljudi planira tu investiciju jako dugo. S druge strane, *rigidna ponuda* znači da ako u jednom trenutku potražnja za novim nekretnina bude veća od postojeće ponude, treba proći određeno vrijeme dok se ta potražnja može zadovoljiti jer je izgradnja nekretnine dug proces. Konačno, tržište nekretnina karakteriziraju *cjenovni pregovori*. Tako je, primjerice, u 2015. godini u Hrvatskoj prosječna postignuta cijena stambenih nekretnina bila 8% manja od tražene cijene (Zane UniCredit Group, 2017).

Konačno, kupnja nekretnine kompliciran je proces koji oduzima puno vremena i novaca, te koja je za većinu ljudi jedna od najvećih i najvažnijih investicija u njihovom cijelom životu, naročito kada se govori o kupnji stambene nekretnine. Osim same prodajne cijene kod ove transakcije javlja se još cijeli niz popratnih troškova kojih kupci nekretnina često nisu niti svjesni. Popratni troškovi značajno variraju od zemlje do zemlje, ali općenito se može govoriti o visini popratnih

troškova većoj od čak 10% od prodajne cijene (HOA, 2012).[18] Neki od tih troškova uključuju i troškove agencijske provizije, naknade hipotekarnih posrednika, troškove pripreme dokumentacije potrebne za prijenos vlasništva, troškove inspekcija, pravne pristojbe, osiguranje vlasništva, troškove seljenja i troškove opremanja (HOA, 2012).[19]

Od ostalih karakteristika, navedenih na slici 4, još se može istaknuti važnost nekretnina kao *alat za zaštitu od inflacije* (*engl. inflation hedge*). Naime, kako ističu Kripa i Korbi (2015) rast cijena ove imovine, kao rezultat rasta opće razine cijena u gospodarstvu, osigurava njihovim vlasnicima veće povrate.

Zbog utjecaja koje promjene u kretanjima na tržištu nekretnina imaju na ukupna kretanja u gospodarstvu, važno je njegovo kontinuirano praćenje, što je kako ističu Boras i Tica (2012) moguće samo detaljnom analizom njegovih segmenata. Stoga se tržište nekretnina najčešće dijeli na:

1. *stambeno tržište;*
2. *tržište uredskih i maloprodajnih poslovnih prostora*
3. *tržište industrijskog prostora, i*
4. *tržište hotelijerskog prostora.*

Važno je napomenuti da se svaka od ovih kategorija može podijeliti na još sitnije potkategorije prema, primjerice, tipu nekretnine i cjenovnom rangu.

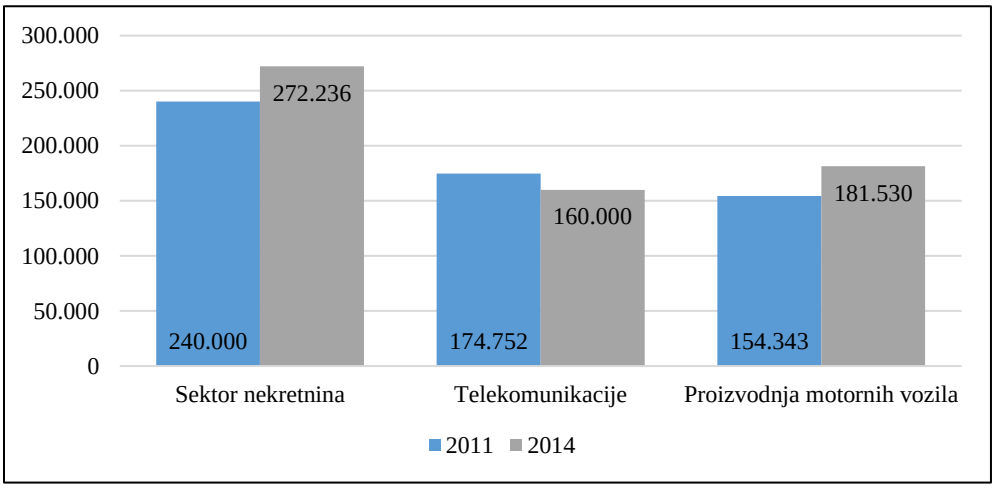
3.2. Značaj tržišta nekretnina za europsko gospodarstvo

Značaj tržišta nekretnina za gospodarstva zemalja diljem svijeta jako je velik. Iz očite činjenice da poslovni ni društveni svijet ne može funkcionirati bez ureda, trgovina, tvornica, kuća i drugih oblika nekretnina koje ovo tržište pruža, jasno je da tržište nekretnina fundamentalan izvor zaposlenosti i ekonomskog rasta. Europsko udruženje za nekretnine (*engl. European Public Real Estate Association – EPRA*) naveli su nekoliko ključnih doprinosa nekretnina u europskom gospodarstvu (EPRA, 2012):

[18] Tako, primjerice, u Austriji popratni troškovi, bez poreza na promet nekretnina, iznose 1% do 3% prodajne cijene, dok u Belgiji variraju od 5% do 12,5% ovisno o regiji. Više o popratnim troškovima prilikom kupnje nekretnine u Europi u European Law Firm (2014).
[19] Porez na promet nekretnina nije ovdje uračunat, s kojim je dodatni trošak kupnje nekretnine još i veći.

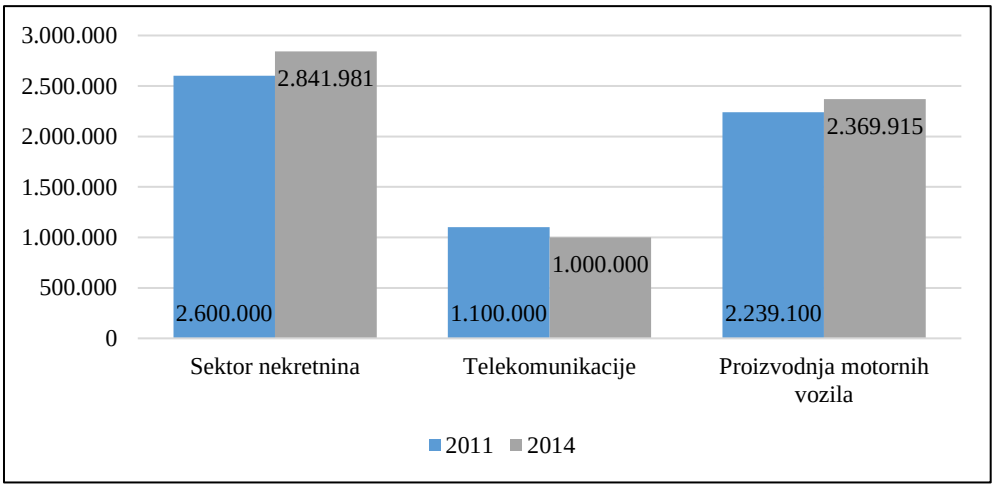
1. ***doprinos gospodarskom rastu i stvaranju radnih mjesta***;
2. ***značajna uloga u poslovanju, industriji i socijalnom životu*****;** *te*
3. ***važan izvor prihoda za europske štediše i umirovljenike.***

Što se tiče doprinosa gospodarskom rastu i stvaranju radnih mjesta, istraživanja su pokazala da nekretnine u svim svojim oblicima doprinose sa skoro 20% ukupne ekonomske aktivnosti u gospodarstvu (EPRA, 2012). Tako je, kao što se može vidjeti iz sljedećeg grafa, samo sektor nekretnina u Europskoj uniji u 2011. godini doprinio sa 240 milijardi eura, više i od telekomunikacijskog sektora i automobilske industrije. U 2014. godini sektor nekretnina doprinio je više u odnosu na 2011. godinu, i to s 272 milijarde eura, ponovno više i od sektora telekomunikacija i automobilske industrije.



Graf 13:Bruto dodana vrijednost u EU po sektorima (2011. i 2014.)
Izvor: Izrada autorice prema podacima sa Eurostata.

Kada je u pitanju zaposlenost, sektor nekretnina u EU u 2014. godini direktno je zapošljavao skoro 3 milijuna ljudi, što je skoro 3 puta više nego što je bilo zaposlenih u sektoru telekomunikacija, te za pola milijuna ljudi više nego u automobilskoj industriji. Prema podacima s Eurostata, u sektoru građevinarstva, a koji je usko povezan s tržištem nekretnina, u 2014. godini u EU bilo je zaposleno 3,17 milijuna ljudi, što dodatno govori o važnosti sektora nekretnina za gospodarstvo Europske unije.



Graf 14:Broj zaposlenih u EU po sektorima (2011. i 2014.)
Izvor: Izrada autorice prema podacima sa Eurostata.

Poslovni prostori obuhvaćaju trgovine, urede, tvornice, hotele, zabavne sadržaje i ostale oblike infrastrukture. Nadalje, novi oblici poslovnih prostora se konstantno pojavljuju, igrajući važnu ulogu u poslovnom ali i privatnom, društvenom, životu. Kako navode iz Europskog udruženja za nekretnine, tržišna vrijednost poslovnih prostora u 2011. godini u EU, bila je preko 5 bilijuna eura. Konačno, dugoročni novčani tokovi, generirani od investicija u nekretnine, pružaju važan izvor diversificiranog dohotka u portfeljima europskih štediša i umirovljenika.

Mihaljek (2005) ističe kako tržište nekretnina ima ključnu ulogu na makroekonomskim kretanjima zbog:

- ✓ povezanosti tržišta nekretnina s odlukama domaćinstava o investiranju, štednji i potrošnji;
- ✓ tržišta nekretnina kao glavne odrednice dinamike bankarskih kredita,
- ✓ važnosti tržišta nekretnina za konkurentnost gospodarstva koja veći dio prihoda ostvaraju od uslužnih djelatnosti, gdje nekretnine predstavljaju temeljni proizvodni činitelj.
- ✓ tržišta nekretnina kao jednog od faktora utjecaja na cijene dionica.

3.3. Determinante cijena nekretnina

Većina kretanja na tržištu nekretnina uvjetovana je cijenama nekretnina i popratnim transakcijskim troškovima. Visoke cijene nekretnina i visoki popratni troškovi mogu demotivirati kupnju nekretnina od strane domicilnog stanovništva, kao i inozemnih investitora, što onda može spriječiti nastanak cijelog niza pozitivnih ekonomskih učinaka na gospodarstvo zemlje. Ovo se naročito događa u situacijama kada kupci smatraju da su cijene i popratni troškovi nerealno visoki.

Problematiku cijena na tržištu nekretnina najbolje je opisao Filipić (2007). Kako navodi Filipić (2007) u usporedbi sa tržištima drugih dobara na kojima odnosi ponude i potražnje reguliraju cijene i količine, na tržištu nekretnina to često nije slučaj. Naime, cijene na tržištu nekretnina podložne su špekulacijama.

Imajući na umu sve navedeno, jasno je da je nužno proučavati što utječe na cijene nekretnina. Iz teorijske literature se mogu izvući četiri sile koje utječu na cijenu nekretnina (CT Realtors, 2017):

1. ***socijalne sile;***
2. ***ekonomske sile;***
3. ***fizičke i ekološke sile; te***
4. ***državne sile.***

Socijalne sile vezane su za trendove u društvu i kulturi. Neki od tih trendova su populacijski trendovi, obiteljska struktura, starenje populacije, trend rasta poslova od kuće, trend rasta ekološke osviještenosti i brige za sigurnost, trend rasta potražnje za vikendicama i kućama za odmor, i sl.

Ekonomske sile vezane su uz mogućnosti kupaca da kupe nekretnine. Stoga, razina dohotka, stopa zaposlenosti, troškovi izgradnje, dostupnost kredita i kamatne stope, troškovi režija i sl., su ekonomske sile koje mogu utjecati na tu mogućnost.

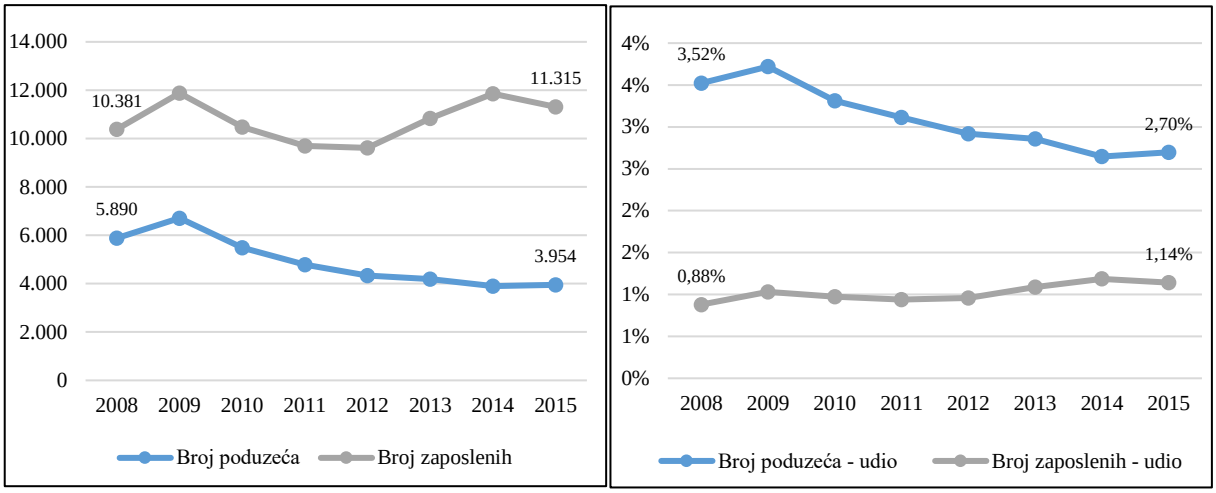
Fizičke i ekološke sile su one karakteristike koje su najuočljivije a odnose se na lokaciju, topografske značke, klimu, promet i transport, te ostale fizičke i ekološke sile.

Konačno, *državne sile* mogu imati značajan utjecaj na cijene nekretnina, naročito po pitanju dodatnih troškova na samu cijenu nekretnine. U tom smislu naročito se ističu porezi, poput poreza na promet nekretnina. Osim poreza, kao državne sile koje mogu utjecati na cijene nekretnina su i monetarna politika, politika rada, kvaliteta obrazovanja i kvaliteta javnih usluga.

3.4.Tržište nekretnina u Hrvatskoj

Tržište nekretnina u Hrvatskoj jako je malo, što potvrđuje i sljedeći graf. Naime, kao što se može uočiti iz grafa 15, udio poduzeća u sektoru nekretnina u ukupnom broju poduzeća smanjivao se kroz promatrano razdoblje da bi u 2015. godini iznosio tek 2,70%, Što se tiče

broja zaposlenih, udio je još i manji, te je u 2015. godini u sektoru nekretnina bilo zaposleno tek 1,14% ukupno zaposlenih u Hrvatskoj.



Graf 15: Broj poduzeća i zaposlenih u sektoru nekretnina i udjeli u ukupnom broju poduzeća i zaposlenih u RH (2008.-2015.)
Izvor: Izrada autorice prema podacima sa Eurostata.

Nositelji vlasti u Hrvatskoj svjesni su utjecaja kojeg ovo tržište ima na gospodarstvo, te se i po nekoliko puta godišnje mogu pronaći razne publikacije o stanju na hrvatskom tržištu nekretnina. Publikacije o kretanjima na hrvatskom tržištu nekretnina izrađuje Hrvatska gospodarska komora, ali i nekoliko većih banaka u Hrvatskoj. Najnoviji podaci o hrvatskom tržištu nekretnina pokazuju da (Zane UniCredit Group, 2017):

- ✓ oporavak od gospodarske krize pozitivno utječe na hrvatsko tržište nekretnina;
- ✓ je prisutan rast transakcija (i dalje najviše u turističkom sektoru);
- ✓ je prisutan blagi porast broja završenih stanova u 2016 godini;
- ✓ je prisutan blagi porast izdanih građevinskih dozvola;
- ✓ je smanjena stopa poreza na promet nekretnina s 5% na 4%;
- ✓ je prisutan daljnji pad prosječnih cijena nekretnina.
- ✓ je najavljena mjera subvencioniranja stambenih kredita;
- ✓ je još uvijek prisutna veća ponuda stambenih nekretnina u odnosu na potražnju za istima;
- ✓ je još uvijek prisutno značajno cjenovno pregovaranje, mada je vidljiva sve veća razlika između tražene i stvarno naplaćene cijene;
- ✓ su industrijski prostori još uvijek najnerazvijeniji segment hrvatskog tržišta nekretnina.

3.5. Utjecaj poreza na promet nekretnina na tržište nekretnina

Porez na promet nekretnina, čiji je utjecaj na tržište nekretnina u fokusu ovog rada, jedan je od troškova koji se vezuje uz kupoprodaju nekretnine. Riječ je o sve učestalijem porezu, te je, s obzirom na važnost i značaj tržišta nekretnina za ekonomije diljem svijeta, od iznimne važnosti znati posljedice koje ovaj porez ima na tržište nekretnina. Navedeno naročito vrijedi ako se uzme u obzir činjenica da je stopa ovog poreza u većini europskih zemalja (značajno) viša od teorijski predložene stope poreza na promet nekretnina od 2%, kao što je već ranije spomenuto.

Dosadašnja empirijska istraživanja koja su proučavala utjecaj poreza na promet nekretnina na tržište nekretnina, nisu naročito brojna, te su uglavnom novijeg datuma. U svim ovim istraživanjima, utjecaj poreza na promet nekretnina promatran je kroz utjecaj na:

- ✓ *prodajne cijene nekretnina*
- ✓ *broj prodanih stanova*

Jedno od prvih ovakvih istraživanja jest istraživanje provedeno u Philadelphiji koje je pokazalo da je rast poreza na promet nekretnina, zabilježen 1988. godine, utjecao na smanjenje prodajnih cijena stambenih nekretnina (Benjamin et al., 1993). Smanjenje prodajne cijene kao posljedice povećanja poreza na promet nekretnina implicira da teret ovog poreza pada na prodavača.

Kasnije istraživanje, provedeno u Torontu, pokazalo je da je porez na promet nekretnina od 1,1% uzrokovao smanjenje u broju prodanih stanova za 15%, te doveo do smanjenja prodajne cijene u visini poreza (Dachis, et al., 2011). Nadalje, Best i Jacobsen Kleven (2013) došli su do rezultata da trenutno smanjenje transakcijskog poreza za 1% povećava aktivnost na tržištu obiteljskih kuća u Velikoj Britaniji za 20% u kratkom roku.

Zanimljivo istraživanje dolazi iz New Yorka i New Yerseya, gdje su kuće i apartmani koji koštaju više od jedan milijun dolara podložni porezu od 1% (*engl. mansion tax*). Istraživanje koje su provedi Kopczuk i Munroe (2014) pokazalo je da prisutnost ovog poreza dovodi do distorzija na tržištu nekretnina jer kupci u startu traže nekretnine koje koštaju manje od milijun dolara[20], tjerajući prodavače da, ili prodaju nekretnine po nižoj cijeni, ili da čekaju za prodaju po istoj cijeni. Prema njihovim procjenama, u periodu od 1996. do 2011. godine, oko 2.800 kupoprodaja nekretnina nije se ni dogodilo u New Yorku zbog postojanja ovog poreza.

[20] Primjerice, nekretnina koja košta 999.999$ nije predmet oporezivanja porezom na promet nekretnina.

Jedno od posljednjih istraživanja na ovu temu jest utjecaj poreza na promet nekretnina na njemačko tržište nekretnina iz 2016. godine. Fritzsche i Vandrei (2016) proučavajući učinak ovog poreza, pokazali su da rast poreza na promet nekretnina za 1 postotni poen dovodi do pada u transakcijama (kupoprodajama obiteljskih kuća) na njemačkom tržištu nekretnina za 6%, u dugom roku.

Iako postoji tek manji broj empirijskih istraživanja, rezultati istih su prilično jednosmjerni, te svi ukazuju na negativan utjecaj poreza na promet nekretnina na cijene nekretnina i/ili broj transakcija.

4. EMPIRIJSKO ISTRAŽIVANJE O DJELOVANJU POREZA NA PROMET NEKRETNINA NA TRŽIŠTE NEKRETNINA

U ovom dijelu rada, s ciljem testiranja hipoteza postavljenih u početnoj fazi istraživanja, identificirati će se utjecaj kojeg porez na promet nekretnina ima na tržište nekretnina u odabranim zemljama. Glavna istraživačka hipoteza postavljena na početku ovog istraživanja glasi:

GH: Porez na promet nekretnina negativno utječe na tržište nekretnina u odabranim europskim zemljama.

Odluka o prihvaćanju odnosno neprihvaćanju glavne hipoteze donijeti će se na temelju testiranja triju pomoćnih istraživačkih hipoteza koje glase:

PH1: Porez na promet nekretnina negativno utječe na prihod poduzeća u sektoru nekretnina.

PH2: Porez na promet nekretnina negativno utječe na broj zaposlenih u sektoru nekretnina.

PH3: Porez na promet nekretnina negativno utječe na broj poduzeća u sektoru nekretnina.

U prvom dijelu ovog poglavlja dana je prostorna i vremenska definicija odabranog uzorka zemalja. Drugi dio ovog poglavlja sadrži opis varijabli i njihove očekivane utjecaje, za promatrani uzorak. U trećem dijelu ovog poglavlja prezentiran je panel model, te su objašnjene metode procjene, dok četvrti dio sadrži rezultate procjene formiranog panel modela. Ovaj dio završava osvrtom na prvotno postavljene istraživačke hipoteze.

4.1. Prostorna i vremenska definicija uzorka

Kako bi se testirale istraživačke hipoteze, prije svega, bilo je potrebno definirati uzorak zemalja nad kojim će se provesti analiza. Sve europske zemlje zajedno nisu reprezentativan uzorak budući da se strukturno značajno razlikuju. S obzirom da se Hrvatska svakako željela uključiti u uzorak, prvi korak u analizi bio je detektirati zemlje slične Hrvatskoj. U tu svrhu koristila se cluster analiza.

Cluster analiza vrsta je multivarijantne statističke analize koja spada u metode klasificiranja, a čiji je osnovni cilj sortirati različite podatke u grupe tako da se maksimizira stupanj sličnosti unutar grupe, uz uvjet da je sličnost s drugim grupama minimalna (Pivac, 2010).[21]

[21] Postoji nekoliko metoda cluster analize, a u ovom radu korištena je hijerarhijska metoda udruživanja kao jedna od najčešće korištenih metoda.

Cluster analiza provela se nad zemljama Europske unije, korištenjem šest temeljnih ekonomskih pokazatelja i to: BDP-a per capita, stope nezaposlenosti, državne i osobne potrošnje, te uvoza i izvoza. Sljedeća tablica prikazuje zabilježene vrijednosti promatranih pokazatelja u 2015. godini kod članica Europske unije.

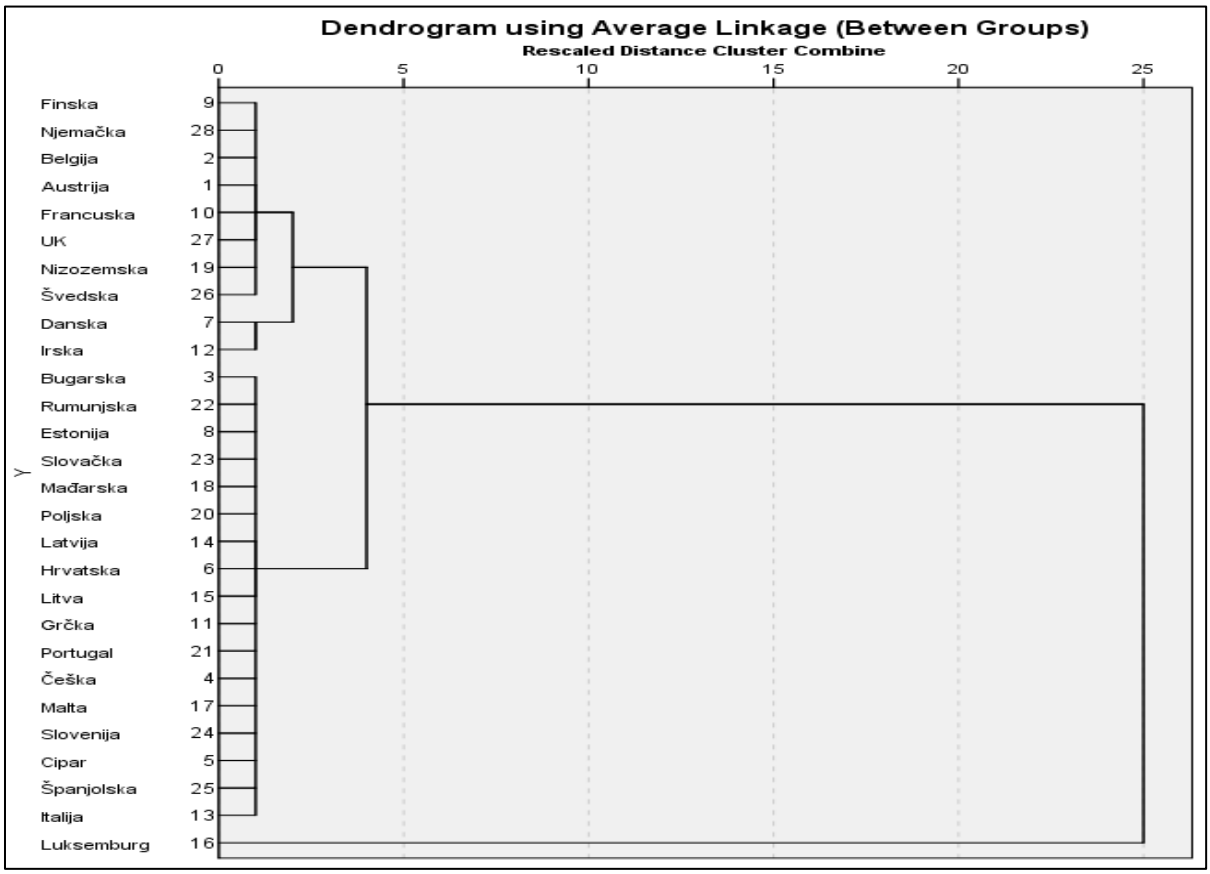
Tablica 1: Glavni ekonomski pokazatelji za zemlje Europske unije (2015. godina)

Zemlja	BDP per capita	Stopa nezaposl.	Državna potrošnja	Izvoz	Osobna potrošnja	Uvoz
Austrija	47.630	5,72	46,85	53,06	72,48	49,05
Belgija	45.068	8,48	42,00	82,95	75,13	81,28
Bugarska	7.612	9,14	27,85	64,11	78,66	63,96
Češka	21.225	5,05	33,10	82,96	66,51	76,83
Cipar	27.587	14,91	38,73	61,22	85,20	60,88
Hrvatska	13.853	16,28	..	49,97	78,46	47,22
Danska	60.001	6,17	40,72	55,23	72,84	47,83
Estonija	17.592	6,19	2,34	79,29	71,11	75,14
Finska	45.212	9,38	40,58	36,84	79,16	37,14
Francuska	41.690	10,36	48,43	29,85	79,14	31,22
Grčka	22.578	24,90	53,41	31,92	90,03	31,77
Irska	64.784	9,40	27,72	123,99	46,60	92,25
Italija	33.912	11,90	42,74	30,02	79,78	27,11
Latvija	14.308	9,87	42,44	58,93	79,03	60,06
Litva	15.342	9,12	9,60	75,86	80,76	76,51
Luksemburg	109.047	6,67	38,27	227,11	46,43	192,42
Malta	25.599	5,39	38,48	143,99	68,37	136,16
Mađarska	14.519	6,81	43,29	90,73	69,37	81,82
Nizozemska	51.255	6,87	40,97	82,46	69,95	71,68
Poljska	14.642	7,50	34,21	49,52	76,43	46,43
Portugal	21.968	12,44	44,49	40,56	83,80	39,83
Rumunjska	9.564	6,81	32,74	41,11	75,65	41,72
Slovačka	18.643	11,48	41,37	93,49	74,37	91,06
Slovenija	23.780	8,96	42,12	77,94	70,82	68,82
Španjolska	30.461	22,06	20,65	33,18	77,49	30,73
Švedska	55.163	7,43	32,06	45,59	71,05	40,84
UK	41.184	5,30	38,62	27,63	84,41	29,22
Njemačka	45.254	4,62	28,24	46,78	73,19	39,21

Izvor: Izrada autorice na temelju podataka sa WDI (2017).

U nastavku je izvršeno grupiranje 28 zemalja članica Europske unije prema šest odabranih ekonomskih pokazatelja koristeći hijerarhijsku metodu udruživanja. Sljedeći prikaz prezentira rezultate tog grupiranja preko dendrograma. Dendrogram ili grafikon matričnog stabla je grafički prikaz grupiranja koji vizualno u dvodimenzionalnom prostoru pokazuje hijerarhiju unutar konačnog klastera, gdje je napravljena podjela kroz binarno stablo (Pivac, 2010).

Iz dendrograma prikazanog na sljedećoj slici može se uočiti da su Hrvatska i još 16 zemalja klasificirane kao slične zemlje prema temeljnim ekonomskim pokazateljima. Riječ je o sljedećim zemljama: Bugarska, Rumunjska, Estonija, Slovenija, Mađarska, Poljska, Latvija, Litva, Grčka, Portugal, Češka, Malta, Slovenija, Cipar, Španjolska i Italija.



Slika 5: Klasifikacija zemalja prema odabranim pokazateljima pomoću dendrograma
Izvor: Izrada autorice u SPSS-u.

Sukladno dobivenim rezultatima grupiranja, navedenih 16 zemalja i Hrvatska činiti će uzorak zemalja u ovom istraživanju. Što se tiče vremenske dimenzije istraživanja, analiza će obuhvatiti period od 2008. do 2013. godine. Ovaj period je uzet zato što za pojedine varijable, prvenstveno za zavisne varijable (broj poduzeća, broj zaposlenih i prihod sektora nekretnina), nije bilo ranije dostupnih podataka. Više o odabranim varijablama slijedi u nastavku teksta.

4.2. Opis korištenih varijabli

Varijable korištene u modelu mogu se podijeliti na zavisne i nezavisne varijable. *Zavisne varijable* vezane su uz tri pomoćne istraživačke hipoteze, gdje je po jedna zavisna varijabla

korištena za svaku istraživačku hipotezu. Riječ je o varijablama vezanima uz sektor nekretnina, i to:

1. ***prihod sektora nekretnina;***
2. ***broj zaposlenih u sektoru nekretnina; te***
3. ***broj poduzeća u sektoru nekretnina.***

Ovi podaci preuzeti su s Eurostata, te su najranije dostupni podaci za promatrane zemlje bili oni iz 2008. godine. Za navedene podatke izračunala se stopa rasta, čime se izgubila jedna godina, ali se dobilo na pouzdanosti modela.

Nezavisne varijable su varijable čiji se utjecaj, na prethodno spomenute zavisne varijable, provjerava u ovom radu. Glavna nezavisna varijabla korištena u ovom radu jest **porez na promet nekretnina**. Dosadašnja istraživanja proučavala su utjecaj ovog poreza na cijene nekretnina i broj prodanih stanova te se, kao što se moglo uočiti iz prethodnog dijela, utjecaj ovog poreza pokazao negativnim. U ovom radu također se očekuje negativan utjecaj ovog poreza na zavisne varijable, ali u manjem opsegu jer je riječ o indirektnom utjecaju. Pritom, najveći negativni utjecaj ovog poreza očekuje se na prihod poduzeća u sektoru nekretnina, jer je pretpostavka da nametanje ovog poreznog opterećenja u određenoj mjeri demotivira kupnje nekretnina, dok se najmanje negativan utjecaj očekuje na broj poduzeća iz sektora nekretnina. Naime, broj poduzeća može i opstati, ali s manjim brojem zaposlenih. Podaci o porezu na promet nekretnina prikupljeni su iz godišnjih publikacija PwC-a o *Globalnim trendovima na tržištu nekretnina*, i iz godišnjih publikacija KPMG-a o *Trendovima na tržištu nekretnina u zemljama središnje i istočne Europe*. PwC je globalna mreža poduzeća sa uredima u 157 zemalja s više od 223 tisuće zaposlenih koja pruža informacije iz područja osiguranja i poreza. KPMG je također globalna mreža profesionalnih poduzeća, prisutna u 155 zemalja s više od 175 tisuća zaposlenih, također osnovana s ciljem pružanja informacija iz područja osiguranja i poreza.

Pored poreza na promet nekretnina, u panel modelu koristiti će se i nekoliko kontrolnih varijabli. Riječ je o varijablama za koje se na temelju ekonomske teorije i prethodnih empirijskih istraživanja pokazalo da, pored poreza na promet nekretnina, također utječu na sektor nekretnina. Prihodi, broj zaposlenih i broj poduzeća u sektoru nekretnina ovise prvenstveno o potražnji za nekretninama koja pak ovisi o nizu faktora, uključujući cijene nekretnina. Za odabir varijabli koristiti će se istraživanje Groh i Lieser (2011) koji su panel analizom provedenom nad 66 zemalja istraživali kako različiti faktori utječu na aktivnosti na

tržištu nekretnina. U ovom radu, a po uzoru na spomenuti rad, uzete su sljedeće kontrolne varijable: BDP per capita, inflacija i domaći krediti odobreni od strane banaka.[22]

Za *ekonomski faktor* u analizu je prvenstveno uzet **BDP per capita**, odnosno njegova stopa rasta, jer je logično očekivati pozitivnu vezu između aktivnosti na tržištu nekretnina i prosperiteta zemlje. Tako su, primjerice, Chin et al. (2006) došli do zaključka da je snažna i stabilna ekonomija najznačajniji faktor u privlačenju stranih investicija u sektor nekretnina. Na ovom tragu, očekuje se pozitivan utjecaj stope rasta BDP-a per capita na varijable vezane za sektor nekretnina.

Druga kontrolna varijabla u ovom istraživanju jest **inflacija** i to njezina godišnja stopa rasta, mjerena indeksom potrošačkih cijena. Inflacija u ovom radu predstavlja zamjenu za cijenu nekretnina. Postoje dva dobra razloga za ovo. Prvo, cijene nekretnina razlikuju se na razini jednog grada, a naročito na razini države, te ih je teško prikupiti.[23] Drugo, kako argumentiraju Lovrinčević i Vizek (2008), ustanovljeno je da je inflacija značajna za kretanje cijena nekretnina, te kada raste opća razina cijena u državi rastu i cijene nekretnina. Zbog činjenice da rast cijena može demotivirati aktivnosti na tržištu nekretnina, očekuje se negativan utjecaj inflacije na varijable vezane za sektor nekretnina.

Za faktor koji oslikava *dubinu financijskog tržišta* uzeti su **domaći krediti odobreni od strane banaka** (kao % BDP-a). Naime, kao što je već ranije spomenuto, kupnja nekretnine podrazumijeva jako visoke troškove, te malo tko može samostalno podnijeti taj trošak. Stoga je logično očekivati da je pristupačnost kredita važna za investicije u ovom sektoru. Na ovom tragu, očekuje se pozitivan utjecaj domaćih kredita banaka na varijable vezane za sektor nekretnina.

Sljedeća tablica prikazuje popis svih varijabli, zajedno s njihovim izvorima i očekivanim utjecajima na zavisne varijable.

[22] Postoji još značajnih faktora koji utječu na aktivnosti na tržištu nekretnina poput, primjerice, urbanizacije i političkog okruženja, ali se radi kvalitete procjene nije željelo pretjerivati s kontrolnim varijablama, pa su stoga u analizu uzete najvažnije kontrolne varijable.

[23] Jedna od karakteristika tržišta nekretnina, navedena još u prethodnom poglavlju, jest netransparentnost i nedostupnost podataka o cijenama nekretnina. Naime, cijene nekretnina podložne su špekulacijama i cjenovnim dogovorima, te su nestabilna varijabla za uključenje u model.

Tablica 2: Popis korištenih varijabli

Varijabla	Oznaka	Izvor	Očekivani utjecaj
Prihod sektora nekretnina	PRIHOD	Eurostat	/
Broj zaposlenih u sektoru nekretnina	ZAPOSLENI	Eurostat	/
Broj poduzeća u sektoru nekretnina	PODUZEĆA	Eurostat	/
Porez na promet nekretnina	PNPN	PwC i KMPM	Negativan
BDP per capita	BDP	WDI	Pozitivan
Inflacija	CPI	WDI	Negativan
Domaći krediti banaka	KREDIT	WDI	Pozitivan

Izvor: Izrada autorice.

4.3. Model i metode procjene

Sukladno prirodi prikupljenih podataka, koji sadrže vremensku i prostornu komponentu, isti će se obraditi panel analizom. Panel analiza ima brojne prednosti u odnosu na, primjerice, višestruku regresiju, Naime, za razliku od višestruke regresije, kod panel analize zavisna varijabla mijenja se i po jedinicama promatranja (zemljama) i po vremenu te, osim što omogućuje veći broj opservacija, daje i preciznije procjene varijabli koje determiniraju zavisnu varijablu (Škrabić Perić, 2014). U svrhu testiranja hipoteza postavljenih u početnoj fazi istraživanja formira se sljedeći panel model:

$$TRŽIŠTE_{it} = \mu + \gamma TRŽIŠTE_{i,t-1} + \beta_1 PNPN_{1it} + \sum_k \beta_k X_{kit} + \alpha_i + \varepsilon_{it}$$

$i = 1,2, \dots 17;\ t = 2009.,2010., \dots 2013.$

Gdje je:

$TRŽIŠTE_{it}$ - jedna od tri varijable vezane za sektor nekretnina u zemlji *i* u razdoblju *t,*

$TRŽIŠTE_{it-1}$ - jedna od tri varijable vezane za sektor nekretnina u zemlji *i* u razdoblju *t-1,*[24]

$PNPN_{it}$ - porez na promet nekretnina u zemlji *i* u razdoblju *t,*

[24] Ova varijabla naziva se još i lagiranom zavisnom varijablom, odnosno zavisnom varijablom s vremenskim pomakom, a označava da se za procjenu utjecaja poreza na promet nekretnina koristi dinamički panel model. Dinamički panel model uzet je zbog prirode tržišta nekretnina. Škrabić Perić (2014) objašnjava kako je većina ekonomskih relacija dinamičke prirode što znači da sadašnja vrijednost neke varijable ovisi o prethodnim vrijednostima te varijable.

X_{kit} - matrica kontrolnih varijabli (k=1,2 i 3),

α_i - slučajna varijabla za zemlju *i*,

ε_{it} - greška relacije zemlje *i* u razdoblju *t*.

Postoji nekoliko različitih procjenitelja za panel modele. Izbor odgovarajućeg procjenitelja ovisi o tome procjenjuje li se statički ili dinamički panel model, o broju promatranih zemalja, te o broju razdoblja. Sukladno karakteristikama prethodno oformljenog panel modela i raspoloživih podataka koristiti će se **Arrellano-Bondov procjenitelj u dva koraka**. Naime, u ovom modelu broj jedinica promatranja (odnosno broj zemalja kojih je 17), veći je od broja razdoblja promatranja (5 godina), čime je zadovoljen uvjet primjene ovog procjenitelja.

Prije procjene samog modela potrebno je spomenuti i dijagnostičke testove koje je potrebno zadovoljiti kako bi se dobiveni rezultati mogli uzeti u razmatranje. Dijagnostički testovi koji će se provesti su Sarganov test[25], te m_1 i m_2 testovi o autokorelaciji u diferencijama rezidualnih odstupanja[26].

4.4. Procjena modela

Prije same procjene modela provjereno je postoji li u modelima problem multikolinearnosti nezavisnih varijabli preko Pearsonovih koeficijenata korelacije između parova potencijalnih varijabli. Kada koeficijent korelacije između dvije nezavisne varijable prijeđe vrijednost 0,8 smatra se da u modelu postoji ozbiljan problem multikolinearnosti (Gujarati i Porter, 2008). Kao što se može uočiti iz sljedeće tablice, ne postoji problem multikolinearnosti između odabranih nezavisnih varijabli, pa su u procjenu modela uključene sve planirane nezavisne varijable.

[25] Arrellano-Bondov procjenitelj riješio je problem pristranosti (kao posljedice uvođenja u model lagirane zavisne varijable čime dolazi do korelacije između lagirane zavisne varijable i slučajne varijable pa su OLS procjenitelji parametara pristrani i nekonzistentni) uvođenjem instrumentalnih varijabli. Međutim, potrebno je provjeriti i valjanost samih instrumenata, što se pak radi Sarganovim testom. Prihvaćanje nulte hipoteze Sarganova testa znači da u modelu ne postoji problem endogenosti. Budući da sa svakom novom instrumentalnom varijablom povećava pristranost procjenitelja, ne treba pretjerivati s brojem varijabli (Škrabić Perić, 2014). Iz ovog razloga u model se uzete samo tri najvažnije kontrolne varijable, a ne više njih.

[26] Nultom hipotezom m1 testa pretpostavlja se nepostojanje autokorelacije prvog reda među diferencijama reziduala, dok se nultom hipotezom m2 testa pretpostavlja nepostojanje autokorelacije drugog reda među diferencijama reziduala (Škrabić Perić, 2014).

Tablica 3: Korelacijska matrica nezavisnih varijabli

	PNPN	BDP	CPI	KREDIT
PNPN	1.0000			
BDP	-0.5084	1.0000		
CPI	-0.3020	0.2221	1.0000	
KREDIT	0.4485	-0.3206	-0.3145	1.000

Izvor: Izračun autorice u Stati.

Tablica 4 prikazuje usporedne rezultate dinamičke panel analize utjecaja poreza na promet nekretnina i ostalih nezavisnih varijabli na tržište nekretnina i to na prihod poduzeća u sektoru nekretnina, broj zaposlenih i broj poduzeća u sektoru nekretnina. Za svaku varijablu vezanu uz tržište nekretnina procijenjen je zaseban model.

Prvo što se treba uočiti iz Tablice 4 jest da je u sva tri modela lagirana zavisna varijabla statistički značajna, čime je opravdana upotreba dinamičkog modela. Nadalje, u sva tri modela zadovoljeni su dijagnostički testovi, pa se dobiveni rezultati mogu uzeti u razmatranje.

Rezultati u tablici 4 pokazuju da, u promatranom uzorku, porez na promet nekretnina ima negativan utjecaj na sve tri promatrane varijable vezane za sektor nekretnina. Pritom, njegov utjecaj nije statistički značaj kada su u pitanju zaposleni u sektoru nekretnina, dok mu je utjecaj statistički značajan pri razini signifikantnosti od 1% kada su u pitanju prihodi sektora nekretnina, odnosno pri razini od 5% kada je u pitanju broj poduzeća u sektoru nekretnina. Nadalje, očekivano, porez na promet nekretnina ima najveći negativni utjecaj na prihode poduzeća iz sektora nekretnina. Koeficijent parametra uz ovu varijablu iznosi -5,4033 te pokazuje da ako se porez na promet nekretnina poveća za 1 postotni poen, da će doći do pada u prihodima poduzeća iz sektora nekretnina za 5,4073 postotna poena. Ovime se prva pomoćna istraživačka hipoteza, koja je pretpostavljala da porez na promet nekretnina negativno utječe na prihode poduzeća iz sektora nekretnina, **može prihvatiti.**

Nadalje, koeficijent parametra uz varijablu broj zaposlenih u sektoru nekretnina, također je negativan te iznosi -0,4785, te pokazuje da ako se porez na promet nekretnina poveća za 1 postotni poen, da će doći do pada broja zaposlenih u poduzećima iz sektora nekretnina za 0,4785 postotnih poena. Međutim, kao što je već ranije navedeno, ovaj utjecaj nije statistički značajan. Međutim zbog dobivenog negativnog predznaka, druga istraživačka hipoteza, koja je

pretpostavljala da porez na promet negativno utječe na broj zaposlenih u poduzećima iz sektora nekretnina, **djelomično se prihvaća**.

Konačno, koeficijent parametra uz varijablu broj poduzeća u sektoru nekretnina, također je negativan te iznosi -0,8689, te pokazuje da ako se porez na promet nekretnina poveća za 1 postotni poen, da će doći do pada broja poduzeća u sektoru nekretnina za 0,8989 postotnih poena. Ovaj negativni utjecaj je i statistički značajan, pa se treća istraživačka hipoteza, koja je pretpostavljala da porez na promet nekretnina ima negativan utjecaj na broj poduzeća u sektoru nekretnina, **može prihvatiti**.

Potencijalno objašnjenje statistički neznačajnog utjecaja poreza na promet nekretnina na broj zaposlenih u sektoru nekretnina, a statistički značajnog utjecaja na broj poduzeća, može biti u tome da nema postupnog gašenja poduzeća, u smislu da se prvo smanjuje broj zaposlenih pa tek onda, u dugom roku, da se gasi samo poduzeće (s nastavkom rasta stope poreza na promet nekretnina). Ovo svakako može biti slučaj ako poduzeća u sektoru nekretnina imaju tek po nekoliko zaposlenika kao što je slučaj, primjerice, s agencijama za nekretnine u Hrvatskoj.[27]

Tablica 4: Utjecaj poreza na promet nekretnina – rezultati panel analize

	PRIHOD	**ZAPOSLENI**	**PODUZEĆA**
Zavisna ($_{t-1}$)	-0.1784***	-0.0355*	-0.5508***
PNPN	**-5.4073*** **	**-0.4785**	**-0.8689** **
BDP	1.5871***	1.1597***	-0.4358
CPI	-16.258***	-0.7583	-3.6801***
KREDIT	-4.03264***	0.0943	-0.5497
Konstantni član	416.376***	-1.7581	68.8878*
DIJAGNOSTIČKI TESTOVI			
Sarganov test (p)	0.2890	0.8882	0.3785
m1	0.7584	0.9433	0.2942
m2	0.7395	0.4711	0.5818

Izvor: Izračun autorice u Stati.
* značajno na razini signifikantnosti od 10%
** značajno na razini signifikantnosti o 5%
*** značajno na razini signifikantnosti od 1%

[27] Tako, primjerice, na grafu 15 u prethodnom dijelu, na kojem je paralelno prikazano kretanje broja zaposlenih i broja poduzeća u sektoru nekretnina u Hrvatskoj, može se uočiti da ukupan zaposlenih raste čak i u periodima kada ukupan broj poduzeća u sektoru nekretnina pada.

Što se tiče utjecaja kontrolnih varijabli, na prihod poduzeća u sektoru nekretnina najveći utjecaj ima inflacija, gdje koeficijent uz ovu varijablu iznosi -16.258 te implicira da ako se stopa inflacije poveća za 1 postotni poen, da će prihodi poduzeća u sektoru nekretnina opasti za 16,25 postotnih poena. Time se utjecaj inflacije pokazao značajnijim za prihode ostvarene u sektoru nekretnina, ne samo u odnosu na porez na promet nekretnina, nego i u odnosu na BDP per capita. Negativan utjecaj domaćih kredita banaka, implicira da se krediti dižu za neke druge svrhe, a ne stjecanje nekretnina.

Što se tiče utjecaja kontrolnih varijabli na broj zaposlenih u sektoru nekretnina, može se uočiti da u modelu najveći utjecaj na broj zaposlenih ima BDP per capita. Pritom, njegov utjecaj na broj zaposlenih je pozitivan. Ostale varijable nisu se pokazale statistički značajne u ovom modelu.

Konačno, što se tiče utjecaja kontrolnih varijabli na broj poduzeća u sektoru nekretnina, iz tablice 4 vidljivo je da najveći, negativan, statistički značajan, utjecaj na broj poduzeća u sektoru nekretnina ima inflacija.

4.5. Osvrt na istraživačke hipoteze

Cilj ovog rada bio je testirati glavnu radnu hipotezu koja je glasila:

GH: Porez na promet nekretnina negativno utječe na tržište nekretnina u odabranim europskim zemalja.

Odluka o (ne)prihvaćanju navedene hipoteze donosi se na rezultata testiranja pomoćnih hipoteza, testiranih u prethodnom potpoglavlju ovog dijela. *Prva istraživačka hipoteza* koja je pretpostavljala negativan utjecaj poreza na promet nekretnina na tržište nekretnina prihvaćena je, te se od tri testirana modela utjecaj ovog poreza pokazao najvećim upravo na prihode. *Druga istraživačka hipoteza*, koja je pretpostavljala negativan utjecaj poreza na promet nekretnina na broj zaposlenih u sektoru nekretnina djelomično je prihvaćena. Naime, testiranjem se dobio očekivani negativni predznak, ali ne i statistički značajan. Konačno, *treća istraživačka hipoteza*, koja je pretpostavljala negativan utjecaj poreza na promet nekretnina na broj poduzeća u sektoru nekretnina, prihvaćena je.

Sukladno dobivenim rezultatima, glavna radna hipoteza koja je pretpostavljala da porez na promet nekretnina negativno utječe na tržište nekretnina u odabranim europskim zemljama, **može se prihvatiti**.

5. ZAKLJUČAK

Porezi su obvezna davanja koja bez izravne i trenutačne protuusluge država uzima od pojedinaca i poduzeća da bi pomoću prikupljenih novaca financirala javne rashode. Iako porezi uvijek oduzimaju dio nečijeg profita i/ili dohotka, sasvim je jasno da je prikupljanje poreza nužno kako bi država mogla ispunjavati svoju ulogu u gospodarstvu. Stoga je na vladama (težak) zadatak da osiguraju da pozitivni učinci oporezivanja uvijek nadmašuju njegove negativne učinke. Europske zemlje koje su tradicionalno socijalne zemlje, po ovom pitanju susreću se sa brojnim problemima jer im je potrebno i znatno više prihoda u odnosu na neke druge zemlje u svijetu. Problem uzrokuje i trend rastuće veličine države koji iziskuje i veće prihode, te posljedično povećanje poreza. Globalizacija, zbog koje visoko mobilni resursi mogu izbjeći visoke stope poreza i prebjeći u zemlje s nižim poreznim opterećenjem, tjera vlade da se sve više okreću oporezivanju manje mobilnih resursa poput nekretnina. Nekretnine predstavljaju imobilan resurs, te se u tom slučaju teško može izbjeći plaćanje poreza.

Upravo zbog navedenih procesa, u posljednje vrijeme može se uočiti tendencija mijenjanja strukture poreznih sustava. Naime, umjesto da povećavaju pojedine vrste poreza, nositelji politika radije šire poreznu osnovnicu uvođenjem novih poreznih oblika, i to onih koji oporezuju relativno slabo ili nimalo mobilnu imovinu odnosno resurse. Porez na promet nekretnina, koji je u fokusu ovog rada, jedan je od takvih poreza na imobilnu imovinu, a kojeg vlade diljem svijeta nameću s poreznom osnovicom koja čini prodajnu cijenu nekretnine.

U teorijskog i empirijskog literaturi prevladava negativan stav o utjecaju poreza na promet nekretnina, i to ne samo na tržište nekretnina, nego i na druge makroekonomske varijable. Što se tiče njegova utjecaja na tržište nekretnina, dosada je višestruko potvrđen njegov negativan utjecaj na cijene nekretnina i na broj prodanih stanova. Istraživanje provedeno u ovom radu potvrdilo je hipotezu da porez na promet nekretnina negativno utječe na tržište nekretnina u odabranim europskim zemljama, Pritom, najveći negativni utjecaj jest na prihode poduzeća iz sektora nekretnina. Ipak, valja naglasiti da su se u pojedinim modelima korištene kontrolne varijable pokazale značajnima na varijable vezane za tržište nekretnina. U prvom redu to je inflacija sa značajnim negativnim utjecajem, te BDP per capita s pozitivnim utjecajem.

Ovo istraživanje tako se pridružuje prethodno provedenim radovima koji su također dokazali njegov negativan utjecaj. S obzirom da ovaj porez ima jako mali udio u poreznim prihodima, a potencijalno velike negativne posljedice, ne samo na tržište nekretnina, nego i na druge makroekonomske varijable, zaista je upitno njegovo postojanje.

LITERATURA

1. Appraisal Institute, (1987). The Appraisal of the Real Estate. *American Institute of Real Estate Appraisers*. Dostupno na: http:/The%20Appraisal%20of%20Real%20Estate.pdf.

2. Barić, V. i Smolić, Š. (2011). Stabilnost zdravstvenog sustava u recesiji. *EFZG Occasional Publications (Department of Macroeconomics)*, Vol.1., sr. 47 – 58.

3. Benjamin, J.D., Coulson, N.E. i Yang, S.X. (1993). Real estate transfer taxes and property values: The Philadelphia story. *The Journal of Real Estate Finance and Economics*, 7(2), 151 – 157.

4. Best, M.C., i Kleven, H.J. (2013). Housing Market Responses to Transaction Taxes: Evidence from Notches and Stimulus in the UK. *London School of Economics*.

5. Bićanić, I., Kukavčić, J., Nikšić, G. i Spajić, V. (2009). Makroekonomika (Intermediate Macroeconomics), elektronički udžbenik. *Ekonomski fakultet Zagreb*. Dostupno na: http://web.efzg.hr/dok/za%20studente/elektronicki%20udzbenici/Krueger_Makroekonomika.pdf.

6. Buettner, T. (2017). Welfare Cost of the Real Estate Transfer Tax. CESIFO Working Paper, No. 6321. Dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2924454.

7. Boras, T. i Tica, J. (2012). Uloga tržišta nekretnina i građevinske industrije u strategiji razvoja malog otvorenog gospodarstva, EFZG Occasional Publications *(Department of Macroeconomics)*, 1, str. 321 – 352.

8. Cantillon, B., Ghysels, J., Mussche, N. i Van Dam, R. (2001). Female employment differences, poverty and care provisions. *European Societies*, 3(4), str. 447 – 469.

9. Chin, W., Dent, P. i Roberts, C. (2006). An exploratory analysis of barriers to investment and market maturity in Southeast Asian cities. *Journal of Real Estate Portfolio Management, 12 (1)*, str. 49 – 57.

10. Clarke, E.H. (1971). Multipart Pricing of Public Goods. *Public Choice*, 11(1), str. 17 – 33.

11. Cornes, R. i Sandler, T. (1996). The Theory of Externalities, Public Goods and Club Goods. *Cambridge University Press*.

12. CT Realtors, (2017). Influences on Real Estate Value. *CT Realtors*. Dostupno na: http://www.ctrealtor.com/unprotected/Ch01.pdf.

13. Dachis, B., Duranton, G. i Turner, M.A. (2011). The effects of land transfer taxes on real estate markets: evidence from a natural experiment in Tornoto. *Journal of Economic Geography*, 12(2), str. 327 – 354.

14. EPRA, (2012). Real Estate in the Real Economy: supporting growth, jobs and sustainability, *European Public Real Estate Association, EPRA*. Dostupno na: http://www.epra.com/media/Real_estate_in_the_real_economy_-_EPRA_INREV_report_1353577808132.PDF.

15. European Law Firm, (2014). Purchasing Real Estate in Europe. European Law Firm. Dostupno na: https://www.european-law-firm.com/guide/purchasing-real-estate-in-europe201011.pdf.

16. Europska komisija, (2010). Taxation trends in the European Union: Data for the EU Member States, Iceland and Norway. *European Commission*. Dostupno na: http://ec.europa.eu/taxation_customs/sites/taxation/files/resources/documents/taxation/gen_info/economic_analysis/tax_structures/2010/2010_full_text_en.pdf.

17. Europska komisija, (2016). Taxation Trends in the European Union: Data for the EU Member States, Iceland and Norway. *European Commission*. Dostupno na: http://ec.europa.eu/taxation_customs/sites/taxation/files/resources/documents/taxation/gen_info/economic_analysis/tax_structures/2016/econ_analysis_report_2016.pdf.

18. Eurostat, (2017). Government revenue, expenditures and main aggregates. *European Commission*. Dostupno na: http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=gov_10a_main&lang=en.

19. Farnsworth, D. (2011). Sales Tax. Saylor Academy. Dostupno na: https://www.saylor.org/site/wp-content/uploads/2011/01/Sales-Tax.pdf.

20. Filipić, P. (2007). Uvod u makroekonomiju stanovanja. *Ekonomski pregled, 58(7-8)*, str. 393 – 420.

21. Fritzsche, C. i Vandrei, L. (2016). The German Real Estate Transfer Tax: Evidence for Single – family home Transactions, *Ifo Working Paper, No. 232*. Dostupno na: https://www.econstor.eu/handle/10419/149554.

22. Gujarati, D.N. i Porter, D.C. (2008). Basic Econometrics, *The McGraw – Hill Series Economics*, New York.

23. Hall, R. i Rabushka, A. (2007). The Flat Tax. *Hoover Institute Press*, California.

24. Hilbers, M.P.L.C., Zacho, M.L. I Lei, M.Q. (2001). Real Estate Market Developments and Financial Sector Soundness, International Monetary Fund, No. 1/129.

25. HOA, (2012). The Hidden Costs of Buying and Owning a Property. *Home Owners Alliance organization*. Dostupno na: http://hoa.org.uk/wp-content/uploads/2012/06/WC-The-Hidden-Costs-of-Buying-and-Owning-a-Property.pdf.

26. ITEP, (2005). The ITEP Guide to Fair State and Local Taxes. *Institute on Taxation and Economic Policy*, Washington.

27. ITEP, (2011). How Sales and Excise Taxes Work. *Institute on Taxation and Economic Policy*, Washington.

28. Kesner – Škreb, M. (2002). Porez na imovinu. *Financijska teorija i praksa, 26(4).*, str. 895 – 897.

29. Kesner – Škreb, M. (2004). Porez na dohodak. *Financijska teorija i praksa, 28(4).*, str. 501 – 504.

30. Kesner – Škreb, M. (2005). Porez na promet. *Financijska teorija i praksa 29 (3)*, str. 317 – 319.

31. Kesner – Škreb, M. i Kuliš, D. (2010). Porezni vodič za građane. *Institut za javne financije*, Zagreb.

32. Klimczak, K. (2010). Determinants of Real Estate Investment. *Economics & Sociology, Vol.3, No. 2*, str. 58 – 66.

33. Kolarek, M. (2014). Studija slučaja: procjena početnih vrijednosti zemljišta grada Krka upotrebom GISS alata. U Zborniku radova „*Uloga geodezije u uređenju zemljišta i upravljanju prostorom*". Hrvatska komora ovlaštenih inženjera geodezije, HKOIG. Dostupno na: http://www.hkoig.hr/assets/Zbornik/zbornik-radova-7simpozija.pdf.

34. Kopczuk, W. i Munroe, D. (2014). Mansion tax: The Effects of Transfer Taxes on the Residential Real Estate Market, No. W20084. *National Bureau of Economic Research*.

35. KPMG, (2015). Guide to Taxes on Real Estate in Central and Eastern Europe: Edition 2015. *KPMG*. Dostupno na: https://assets.kpmg.com/content/dam/kpmg/pdf/2015/07/Raport-KPMG-CEE-Guide-to-Taxes-on-Real-Estate-in-CEE-2015.pdf.

36. Kripa, D. i Korbi, A. (2015). Protection from Inflation by Investing in Real Estates, Albanian Case, *Scientific Bulletin – Economic Sciences, 14(2*), str. 45 – 53.

37. Kukić, N. i Švaljek, S. (2012). Porez na nekretnine: osnovne značajke i rasprava o uvođenju u Hrvatskoj. *Economic Trends & Economic Policy, 22(132),* str. 49 – 91.

38. Learn Mortgage, (2017). The Value of Real Estate. *Learn Mortga*ge. Dostupno na: https://mortgage.fastclass.com/docs/mortgage/MLPP4e_Ch11_PP.pdf.

39. Lieser, K. i Groh, P.A. (2011). The attractiveness of 66 countries for institutional real estate investments. *Journal of Real Estate Portfolio Management, 17(3),* str. 191 – 211.

40. Lovrinčević, Ž. i Vizek, M. (2008). Determinante cijena nekretnina u Republici Hrvatskoj i potencijalni učinci liberalizacije tržišta nekretnina, *Ekonomski pregled, 59(12),* str. 723 – 740.

41. Malešević Perović, L. i Čorić, B. (2013). Makroekonomija: Teorija i politika. *Sveučilište u Splitu,* Ekonomski fakultet Split, Split.

42. Mihaljek, D. (2005). Slobodno kretanje kapitala, tržište nekretnina i turizam: blagodat ili nevolja za Hrvatsku na putu u Europsku uniju? U K. Ott, ur. *Pridruživanje Hrvatskoj Europskoj uniji: ususret izazovima pregovora*, Zagreb. Institut za javne financije: *Friedrich Eberg Stiftung,* str. 181 – 222.

43. MFIN, (2017). Statistika i izvješća: Vremenske serije podataka, *Ministarstvo financija Republike Hrvatske*. Dostupno na: http://www.mfin.hr/hr/vremenske-serije-podataka.

44. Narodne novine, (2016). Zakon o financiranju jedinica lokalne i područne (regionalne) samouprave. *Narodne novine d.d.,* Zagreb, br. 115/16.

45. Narodne novine, (2016). Zakon o porezu na promet nekretnina. *Narodne novine d.d.,* Zagreb, br. 115/16.

46. Narodne novine, (2016). Zakon o porezu na dohodak. *Narodne novine d.d.,* Zagreb. br. 115/16.

47. Narodne novine, (2016). Zakon o porezu na dodanu vrijednost, *Narodne novine d.d.,* Zagreb., br. 115/16.

48. Narodne novine, (2016). Zakon o porezu na dobit, *Narodne novine d.d.,* Zagreb, br. 115/16.

49. Nikolić, N. i Pečarić, M- (2007). Osnove monetarne ekonomije. *Naklada Protuđer,* Split.

50. OECD, (2016). The OECD classification of taxes and interpretative guide. *OECD Revenue Statistics*. Dostupno na: https://www.oecd.org/tax/tax-policy/oecd-classification-taxes-interpretative-guide.pdf.

51. Ott, K., Bajo, A., Pitarević, M., Bratić, V. i Urban, I. (2003). Proračunski vodič za građane. *Institut za javne financije,* Zagreb.

52. Pivac, S. (2010). Statističke metode, nastavni materijali. *Ekonomski fakultet Split*.

53. PwC, (2014). Real Estate Going Global: Worldwide Country Summaries 2012/2013, *PwC*.

54. Ravnić, A. (1996). Socijalna država i država blagostanja. *Revija m socijalmi polititi* 3 (4), str. 239 – 250.

55. Samuelson, P.A. i Nordhaus, W.D. (2010). Ekonomija, 19. izdanje, *MATE d.o.o.*, Zagreb.

56. Shimizu, C. (2014). What is commercial property? Concepts and classifications, *Preparation of an International Handbook on Commercial Property Price*. Dostupno na: https://www.ecb.europa.eu/events/pdf/conferences/140929/1_Shimizu_What_is_commercial_property_Concepts_and_classifications_9_45_Presentation.pdf?23ac2f7826299056c98fa88d911cdbd1.

57. Snyder, M. (2014). A List of 97 Taxes Americans Pay Every Year. *The Economic Collapse*. Dostupno na: http://theeconomiccollapseblog.com/archives/a-list-of-97-taxes-americans-pay-every-year.

58. Škrabić Perić, B. (2014). Analiza vremenskih serija i panel podataka – nastavni materijali, *Ekonomski fakultet Split*.

59. Taylor – Gooby, P. (2004). New risks, new welfare: The transformation of the European welfare state. *Oxford University Press*.

60. Tkalac Verčić, A., Sinčić Ćorić, D., i Pološki Vokić, N. (2010). Priručnih za metodologiju istraživačkog rada. *MEP*, Zagreb.

61. Trading Economics, (2017a). Government Spending to GDP by Country database. *Trading Economics*. Dostupno na: https://tradingeconomics.com/.

62. Trading Economics, (2017b). Income Tax Rate by Country database. *Trading Economics*. Dostupno na: https://tradingeconomics.com/.

63. Trading Economics, (2017c). Sales Tax Rate by Country database. *Trading Economics*. Dostupno na: https://tradingeconomics.com/.

64. Udovičić, A. i Mečev, D. (2011). Javno – privatno partnerstvo: Primjenjivost iskustava na Republiku Hrvatsku. *Praktični menadžment, Vol. 2., No. 2*., str. 40 – 50.

65. Van Ommeren J. i Van Leuvensteijn, M. (2003). New Evidence of the Effects of Transaction Costs on Residential Mobility. *CPB Discussion Paper*, No. 18. Dostupno na: https://ideas.repec.org/p/cpb/discus/18.html.

66. WDI, (2017). World Development Indicators. *Svjetska banka*.

67. World Bank, (2014). Paying Taxes 2014: The Global Picture: A Comparison of Tax Systems in 189 Economies Worldwide. *World Bank*. Dostupno na: https://www.pwc.com/gx/en/paying-taxes/assets/pwc-paying-taxes-2014.pdf.

68. Zane UniCredit Group, (2017). Godišnji pregled tržišta nekretnina u Hrvatskoj 2016. Zane UniCredit Group. Dostupno na: http://www.zane.hr/wps/wcm/connect/5f9a2a46-f1bf-475d-81ed-0a6c259a7ac9/Pregled+nekretnina+2016.pdf.

69. Zhongmei, W. (2008). Anti – dumping Towards China and Non – market Economy Issues. *World Economy Study, 9,* 002.

POPIS SLIKA, GRAFOVA I TABLICA

SLIKE

Slika 1: Pad poreza na dobit u 189 zemalja svijeta 9
Slika 2: Regresivni, proporcionalni i progresivni porezi 13
Slika 3: Utjecaj poreza na promet pri različitim razinama dohotka 17
Slika 4: Karakteristike tržišta nekretnina 23
Slika 5: Klasifikacija zemalja prema odabranim pokazateljima pomoću dendrograma 34

GRAFOVI

Graf 1: Trendovi u veličini države, svjetske velesile i RH (2000. – 2015.) 7
Graf 2: Udio državne potrošnje i prihoda u BDP-u, svjetske velesile i RH (2000. – 2015.) 8
Graf 3: Stopa participacije radne snage u EU i RH, muškarci i žene (1990- - 2016.) 10
Graf 4: Populacija stara 65 godina i više, % ukupne populacije, EU i RH (1960 - 2016.) 11
Graf 5: Stopa ovisnog starijeg stanovništva, EU i RH (1960- - 2016.) 11
Graf 6: Stope poreza na dobit i poreza na dohodak, svjetske velesile (2000/2007. – 2016.) .. 15
Graf 7: Stope poreza na promet, svjetske velesile (2007. – 2016.) 17
Graf 8: Stope poreza na dobit u Europskoj uniji (2001. i 2016. godina) 18
Graf 9: Stope PDV-a u Europskoj uniji (2001. i 2016. godina) 19
Graf 10: Stope poreza na dohodak u Europskoj uniji (2001. i 2016. godina) 19
Graf 11: Stopa poreza na promet nekretnina, svjetske sile i RH (2017) 21
Graf 12: Porez na promet nekretnina i udio u ukupnim poreznim prihodima ('02.-'15.) 22
Graf 13:Bruto dodana vrijednost u EU po sektorima (2011. i 2014.) 26
Graf 14:Broj zaposlenih u EU po sektorima (2011. i 2014.) 27
Graf 15: Broj poduzeća i zaposlenih u sektoru nekretnina i udjeli u ukupnom broju poduzeća i zaposlenih u RH (2008.-2015.) 29

TABLICE

Tablica 1: Glavni ekonomski pokazatelji za zemlje Europske unije (2015. godina) 33
Tablica 2: Popis korištenih varijabli 37
Tablica 3: Korelacijska matrica nezavisnih varijabli 39
Tablica 4: Utjecaj poreza na promet nekretnina – rezultati panel analize 40

SAŽETAK

Cilj ovog rada bio je kvantificirati utjecaj kojeg porez na promet nekretnina ima na tržište nekretnina u odabranim europskim zemljama. U tu svrhu koristila se panel analiza, a promatrani period obuhvatio je razdoblje od 2009. do 2013. godine. Rezultati istraživanja pokazali su da porez na promet nekretnina ima jak i negativan, statistički značajan utjecaj na prihode ostvarene u sektoru nekretnina. Nadalje, rezultati su pokazali negativan, ali ne i statistički značajan, utjecaj poreza na promet nekretnina na broj zaposlenih u sektoru nekretnina. Konačno, rezultati istraživanja pokazali su da porez na promet nekretnina ima negativan, statistički značajan, utjecaj na broj poduzeća u sektoru nekretnina. Međutim, valja napomenuti da su se neke kontrolne varijable pokazale značajnijima po pitanju utjecaja na tržište nekretnina i to prvenstveno inflacija i BDP per capita.

Ključne riječi: tržište nekretnina, porez na promet nekretnina, inflacija, BDP per capita

SUMMARY

The aim of this paper was to quantify the impact of real estate transfer tax on the real estate markets in selected European countries. Panel analysis was used for this purpose, and the observed period covered the period from 2009. to 2013. The results showed that real estate transfer tax has strong and negative, statistically significant, impact on the income earned in the real estate sector. Further, the results showed that the real estate transfer tax has a negative, although not statistically significant, impact on the number of employees in the real estate sector. Finally, research showed that real estate transfer tax has a negative, statistically significant impact on the number of companies in the real estate sector. However, it should be noted that some control variables have shown more significant impact on the real estate market, primarily inflation and GDP per capita.

Key words: real estate market, real estate transfer tax, inflation, GDP per capita.