Analiza utjecaja sustava poreza i socijalnih naknada na isplativost rada u Republici Hrvatskoj upotrebom mikrosimulacijskih modela

Bezeredi, Slavko

Doctoral thesis / Disertacija

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Economics and Business / Sveučilište u Zagrebu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:148:021742

Rights / Prava: Attribution-NonCommercial-ShareAlike 3.0 Unported/Imenovanje-Nekomercijalno-Dijeli pod istim uvjetima 3.0

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



Repository / Repozitorij:

REPEFZG - Digital Repository - Faculty of Economcs & Business Zagreb







Sveučilište u Zagrebu

Ekonomski fakultet

Slavko Bezeredi

ANALIZA UTJECAJA SUSTAVA POREZA I SOCIJALNIH NAKNADA NA ISPLATIVOST RADA U REPUBLICI HRVATSKOJ UPOTREBOM MIKROSIMULACIJSKIH MODELA

DOKTORSKI RAD

Zagreb, 2020.



Sveučilište u Zagrebu

Ekonomski fakultet

Slavko Bezeredi

ANALIZA UTJECAJA SUSTAVA POREZA I SOCIJALNIH NAKNADA NA ISPLATIVOST RADA U REPUBLICI HRVATSKOJ UPOTREBOM MIKROSIMULACIJSKIH MODELA

DOKTORSKI RAD

Mentor:
prof. dr. sc. Nataša Erjavec

Zagreb, 2020.



University of Zagreb

Faculty of Economics and Business

Slavko Bezeredi

ANALYSIS OF THE IMPACT OF THE TAX-BENEFIT SYSTEM ON WORK INCENTIVES IN THE REPUBLIC OF CROATIA USING MICROSIMULATION MODELS

DOCTORAL THESIS

Supervisor:
prof. dr. sc. Nataša Erjavec

Zagreb, 2020

PODACI I INFORMACIJE O DOKTORANDU

Ime i prezime: Slavko Bezeredi

Datum i mjesto rođenja: 5. 12. 1987., Zagreb

Naziv završenog fakulteta i godina diplomiranja: Prirodoslovno matematički fakultet – Matematički odsjek, Zagreb, 2011.

Naziv poslijediplomskog studija, fakultet i godina diplomiranja: Specijalistički poslijediplomski studij, Statističke metode za ekonomske analize i prognoziranje, Ekonomski fakultet Sveučilišta u Zagrebu, 2015.

PODACI O DOKTORSKOM RADU

1. Naslov doktorskog rada: Analiza utjecaja sustava poreza i socijalnih naknada na isplativost rada u Republici Hrvatskoj upotrebom mikrosimulacijskih modela

2. Fakultet na kojem je rad obranjen: Ekonomski fakultet Sveučilišta u Zagrebu

Povjerenstvo za ocjenu podobnosti teme doktorskog rada:

1. prof. dr. sc. Boris Cota (predsjednik)
2. prof. dr. sc. Nataša Erjavec
3. dr. sc. Ivica Urban

Datum prihvaćanja teme: 18. lipnja 2019.

Mentor: prof. dr. sc. Nataša Erjavec

Povjerenstvo za ocjenu doktorskog rada:

1. prof. dr. sc. Boris Cota (predsjednik)
2. prof. dr. sc. Nataša Erjavec
3. dr. sc. Ivica Urban

Povjerenstvo za obranu doktorskog rada:

1. prof. dr. sc. Boris Cota (predsjednik)
2. prof. dr. sc. Nataša Erjavec
3. dr. sc. Ivica Urban

Datum obrane doktorskog rada: 20. svibnja 2020.

INFORMACIJE O MENTORU

prof. dr .sc. Nataša Erjavec

Nataša Erjavec (nerjavec@efzg.hr), profesor je u trajnom zvanju na Katedri za Statistiku, Ekonomskog fakulteta Sveučilišta u Zagrebu. Nositelj je i izvodi više kolegija doktorskog, poslijediplomskog i integriranog studija na Ekonomskom fakultetu u Zagrebu. Koautor je dva sveučilišna udžbenika, te više od 80 znanstvenih radova. Kao istraživač, sudjelovala je na više znanstvenih istraživačkih projekata Ministarstva znanosti RH i Hrvatske zaklade za znanost. Član je profesionalnih udruženja; International Association of Survey Statisticians, Hrvatsko statističko društvo, Society for the Study of Emerging Markets, Hrvatsko društvo za operacijska istraživanja i Eurasian Business and Economics Society. Glavna je urednica međunarodnog znanstvenog časopisa Croatian Review of Economic, Business and Social Statistics (CREBSS), član uređivačkog odbora međunarodnog znanstvenog časopisa "Acta Turistica", te više odbora međunarodnih znanstvenih konferencija. Obnašala je dužnosti pročelnice Katedre za statistiku i Prodekanice za znanost, poslijediplomske studije i doktorate na Ekonomskom fakultetu Sveučilišta u Zagrebu. Uže područje znanstveno istraživačkog interesa su ekonometrijski modeli, analiza vremenskih nizova, kvantitativne metode u financijama i financijska ekonometrija.

Više na: https://www.bib.irb.hr/pregled/znanstvenici/126386?autor=126386

Slavko Bezeredi

IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je doktorski rad ***Analiza utjecaja sustava poreza i socijalnih naknada na isplativost rada u Republici Hrvatskoj upotrebom mikrosimulacijskih modela*** isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija.

Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

U Zagrebu, 20. svibnja 2020.



(vlastoručni potpis doktoranda)

ZAHVALE

Najprije zahvaljujem financijerima doktorskog studija: prije svega Institutu za javne financije (IJF), donaciji gospođe Jill Benderly, te Hrvatskoj zakladi za znanost (HRZZ) u sklopu projekta „Primjena mikrosimulacijskih modela u analizi poreza i socijalnih naknada u Hrvatskoj – AMMATSBC“ (UIP-2014-09-4096).

Veliko hvala mentorici prof.dr.sc. Nataši Erjavec s kojom sam nastavio uspješnu suradnju s poslijediplomskog specijalističkog studija na kojemu mi je također bila mentorica. Puno hvala na svim sugestijama i vođenju tokom cijelog doktorskog studija, a posebno prilikom izrade doktorske disertacije. Zahvaljujem i kolegi dr.sc. Ivici Urbanu, voditelju HRZZ projekta AMMATSBC u sklopu kojega je proizašao veći dio ove disertacije, na mnogim korisnim savjetima i sugestijama prilikom pisanja disertacije, a i svim ostalim savjetima u vezi moje znanstvene izobrazbe. Zahvaljujem i prof.dr.sc. Borisu Coti, predsjedniku Povjerenstva za ocjenu i obranu disertacije, na svim korisnim sugestijama u cilju poboljšanja disertacije. Zahvaljujem bivšoj ravnateljici Instituta za javne financije prof.dr.sc. Katarini Ott i sadašnjem ravnatelju izv.prof.dr.sc. Vjekoslavu Bratiću što su bili puni razumijevanja prilikom pisanja disertacije i u prvi plan stavljali završetak doktorskog studija. Na kraju, puno hvala mojim roditeljima i obitelji.

Rezultati disertacije se temelje na EUROMOD-u (verziji H1.0+) koji održava, razvija i njime upravlja Institut za društvena i ekonomska istraživanja (ISER) na Sveučilištu u Essexu, u suradnji s nacionalnim timovima članica EU-a, a proces njegovog proširenja i ažuriranja financijski podupire EU Program za zapošljavanje i socijalne inovacije „EaSI” (2014. - 2020.). Zahvalan sam svim ljudima koji su doprinijeli razvoju EUROMOD-a, ali i svim kolegama s projekta AMMATSBC unutar kojeg je razvijen mikrosimulacijski model hrvatskih poreza i socijalnih naknada – *miCROmodA* - korišten u ovoj disertaciji. Zahvalan sam Eurostatu na pristupu mikropodatcima iz EU Ankete o dohotku i životnim uvjetima (EU-SILC) za Sloveniju, te HRZZ-u koji je u sklopu projekta AMMATSBC financirao nabavu podataka iz Ankete o dohotku stanovništva za Hrvatsku od Državnog zavoda za statistiku. Rezultati i njihovo tumačenje su moja odgovornost.

SAŽETAK

U disertaciji se analizira utjecaj sustava poreza, socijalnih naknada i politika za povećanje isplativosti rada na poticaje za rad i stopu siromaštva u Republici Hrvatskoj i Republici Sloveniji. Promatraju se osobe izvan rada i njihov hipotetski prelazak u svijet rada, a kao glavni pokazatelj isplativosti rada izračunava se participacijska porezna stopa (PPS), koja mjeri koliki će dio bruto plaće ostvarene na novom poslu biti izgubljen iz proračuna kućanstava zbog povećanja iznosa plaćenih poreza i smanjenja iznosa primljenih socijalnih naknada. Prvo se analizira isplativost rada na temelju sustava poreza i socijalnih naknada koji je vrijedio u 2017. Nakon toga, prema uzoru na britanski WTC (engl. *Working Family Tax Credit*) implementiraju se dvije vrste politika za poboljšanje isplativosti rada te se analizira kako takve politike djeluju na isplativost rada. Budući da ne postoji opći konsenzus oko dizajna optimalne politike za povećanje isplativosti, definiraju se dvije vrste „naknada za zaposlene“, koje se razlikuju u pogledu načina izračuna dohodovnog cenzusa. Analiza se provodi koristeći hipotetske i stvarne anketne podatke, a glavni alat koji se koristi su mikrosimulacijski modeli, miCROmodA za Hrvatsku i slovenski modul EUROMOD-a za Sloveniju.

Rezultati pokazuju da je prosječan PPS za osobe izvan rada u Hrvatskoj umjerene veličine uz značajan postotak osoba s visokom i vrlo visokim PPS-om. Utvrdilo se da vjerojatnost vrlo visokog PPS-a za osobe izvan rada pada sa stupnjem njihova obrazovanja i s razinom tržišnog dohotka koji ostvaruju njihov supružnik i ostali članovi kućanstva, a raste s brojem maloljetne djece. Nadalje, komparativna analiza isplativosti rada između Hrvatske i Slovenije sugerira da Slovenija ima viši PPS i veći udio osoba izvan rada s visokom i vrlo visokom PPS-om nego Hrvatska. Što se tiče analize politika za povećanje isplativosti rada u obje zemlje, rezultati pokazuju kako su obilježja politika vrlo važna, a odabir odgovarajućeg tipa politike ovisi o postavljenim ciljevima. Tako naknade za zaposlene koje se provjeravaju prema dohotku obitelji imaju bolje redistributivne učinke te veći utjecaj na povećanje poticaja za rad najranjivijih skupina (samohrani roditelji, parovi u kojima nitko ne radi, itd.), ali istovremeno smanjuju poticaje za rad drugog odraslog člana u paru. Što se tiče ukupnog utjecaja na poboljšanje poticaja za rad, bolji utjecaj ima naknada za zaposlene koja se provjerava s obzirom na dohodak pojedinca i koja je po svojem dizajnu raspoređena na veći broj primatelja.

Ključne riječi: participacijska porezna stopa; poticaji za rad; politike za povećanje isplativosti rada; miCROmodA; EUROMOD; Hrvatska; Slovenija

SUMMARY

Generous social benefits systems may reduce work incentives of unemployed and inactive persons. Namely, if inactive and unemployed persons lose their right to generous benefits from the social system through their employment, this may reduce the incentives for such persons to find and accept new employment. This fact has led more than half of EU countries to introduce the so-called "make work pay" policies that aim to increase the disposable income of low-income earners.

This dissertation analyzes the impact of the tax-benefit system and make work pay policies on work incentives and poverty reduction in the Republic of Croatia and the Republic of Slovenia. Persons out of work and their hypothetical transitions to employment are considered. As the main indicator of work incentives the participation tax rate (PTR) is estimated, which represents a portion of additional income that is lost because taxes increase and benefits decrease in transition of a person from non-employment into employment. Work incentives based on the 2017 tax-benefit system are first analyzed. Second, selected make work pay policies are introduced and their impact on work incentives is assessed. Since there is no general consensus on the design of optimal make work pay policies, there are two types of policies defined, family based and individual based in-work benefits, which are implemented based on the British Working Family Tax Credit (WTC). The analysis is carried out using hypothetical and survey data and the main tools used are microsimulation models of tax-benefit system. miCROmodA, a tax-benefit microsimulation model for Croatia, is used for Croatia and EUROMOD for Slovenia. In both microsimulation models are implemented the policies from the Croatian and Slovenian tax-benefits systems that were valid on June 30, 2017.

Work incentives based on the 2017 tax-benefit system are first analyzed. The results show that the average PTR for unemployed and inactive persons in Croatia is a moderate size (31,2%), with a significant percentage of persons with high and very high PTR (9,0%). Furthermore, 2.8% of unemployed and inactive persons in Croatia have very high PTR. The results of the logit model show that the likelihood of a very high PTR for unemployed and inactive persons in Croatia declines with their educational attainment and with the level of market income of their spouse and other household members, while it increases with the number of dependent children. A comparative analysis of Croatia and Slovenia found that Slovenia has a higher average PTR than Croatia and it amounts 43.9%, which is 12.7 percentage points higher than in Croatia. Slovenia has a much higher share of persons with

high and very high PTR, which is 27.1%, and in Croatia this share is 9%. However, it turns out that Slovenia has far fewer inactive and unemployed persons than Croatia: Slovenia has 91 thousand unemployed and inactive persons, while Croatia has 439 thousand.

As for the analysis of the introduced make work pay policies in both countries, the results show that family based in-work benefit significantly improve work incentives of the most vulnerable groups such as lone parents and one-earner couples. More precisely, family based in-work benefit in Croatia decrease PTR by 19.6 percentage points (from 42.9% to 23.2%) and individual based in-work benefit decreases it by 8.2 percentage points. For one-earner couples, the family based in-work benefit reduces the PTR by 12.6 percentage points (from 39.2% to 26.6%), while the individual based in-work benefit reduces it by 7.3 percentage points. In Slovenia, PTR of one-earner couples amounts 59.3%, the family based in-work benefit decreases PTR by 6.9 percentage points, and the individual based in-work benefit reduces it by 1.6 percentage points. As for lone parents in Slovenia whose PTR amounts 56.2%, the family based in-work benefit reduces the PTR by 4.6 percentage points and the individual based in-work benefit reduces it by 1.6 percentage points. Thus, for both countries, it is shown that the family based in-work benefit are more effective in reducing PTR of the most vulnerable groups than individual based in-work benefit. Furthermore, the family based in-work benefit is more effective in reducing poverty rates than individual based in-work benefit. However, family based in-work benefit has a negative impact on the work incentives of two-earner couples. Namely, the family based in-work benefit increases PTR by 5.9 percentage points (from 29.4% to 35.3%) in Croatia, and in Slovenia PTR grows by 6.3 percentage points (from 41.5% to 47.8%). On the other hand, in both countries, individual based in-work benefit is less effective in improving the work incentives of the mentioned vulnerable groups, but this policy improves work incentives of all groups, including two earner couples.

To sum up, in both countries, it has been shown that there are many more unemployed and inactive persons for whom the family based in-work benefit has negative impact on work incentives than those in which it is particularly effective. Therefore, on average, individual based in-work benefit benefits have proven to be more effective in increasing work incentives of inactive and unemployed persons than the family-based in-work benefit.

Keywords: participation tax rate; work incentives; make work pay policies; miCROmodA; EUROMOD; Croatia; Slovenia

SADRŽAJ

SAŽETAK ..... **I**
SUMMARY ..... **III**
1. UVOD **1**
1.1. Predmet istraživanja 1
1.2. Ciljevi istraživanja 4
1.3. Hipoteze istraživanja 5
1.4. Metode istraživanja 8
1.5. Očekivani znanstveni doprinos 10
1.6. Struktura disertacije 11
2. TRŽIŠTE RADA I ISPLATIVOST RADA **15**
2.1. Komparativni pregled tržišta rada i siromaštva u Republici Hrvatskoj i Europskoj uniji 15
2.1.1. Pregled zaposlenosti, nezaposlenosti i neaktivnosti *15*
2.1.2. Potencijalno zapošljive osobe koje se nalaze izvan rada i potencijalna radna snaga *25*
2.1.3. Socijalni transferi i siromaštvo *27*
2.2. Isplativost rada: koncept i mjerenje 30
2.3. Politike za povećanje isplativosti rada 35
3. METODOLOGIJA IZRAČUNA POKAZATELJA ISPLATIVOSTI RADA I OPIS PODATAKA **43**
3.1. Pokazatelji isplativosti rada 43
3.1.1. Participacijska porezna stopa *43*
3.1.2. Neto stopa zamjene *45*
3.1.3. Glavne razlike između PPS-a i NSZ-a *46*
3.2. Regresijski modeli korišteni u analizi 46
3.2.1. Heckmanov selekcijski model *46*
3.2.2. Logit model *48*
3.3. Podaci i varijable 49
3.3.1. Anketni podaci 50
3.3.2. Predviđanje plaća za neaktivne i nezaposlene osobe *56*
3.3.3. Mikrosimulacijski modeli poreza i socijalnih naknada 63
4. ISPLATIVOST RADA U REPUBLICI HRVATSKOJ I REPUBLICI SLOVENIJI **65**
4.1. Opis sustava poreza i socijalnih naknada u Republici Hrvatskoj 65
4.2. Analiza hipotetskih kućanstava u Republici Hrvatskoj 69
4.3. Empirijska analiza isplativosti rada u Republici Hrvatskoj 77
4.4. Opis sustava poreza i socijalnih naknada u Republici Sloveniji 82
4.5. Analiza hipotetskih kućanstava u Republici Sloveniji 87
4.6. Empirijska analiza isplativosti rada u Republici Sloveniji 95
4.7. Komparativna analiza isplativosti rada za Republiku Hrvatsku i Republiku Sloveniju 98
5. UVOĐENJE POLITIKA ZA POVEĆANJE ISPLATIVOSTI RADA **107**
5.1. Učinci uvođenja politika za povećanje isplativosti rada u Republici Hrvatskoj 107
5.1.1. Definicije reformskih politika u Republici Hrvatskoj *107*
5.1.2. Analiza uvedenih reformi na hipotetskim kućanstvima u Republici Hrvatskoj *110*

5.1.3. Analiza utjecaja uvedenih reformi na siromaštvo i raspodjelu dohotka u Republici Hrvatskoj *115*
5.1.4. Analiza pokazatelja isplativosti rada u Republici Hrvatskoj *120*
5.2. Učinci uvođenja politika za povećanje isplativosti rada u Republici Sloveniji 125
5.2.1. Definicije reformskih politika u Republici Sloveniji *125*
5.2.2. Analiza uvedenih reformi na hipotetskim kućanstvima u Republici Sloveniji *128*
5.2.3. Analiza utjecaja uvedenih reformi na siromaštvo i raspodjelu dohotka u Republici Sloveniji *133*
5.2.4. Analiza pokazatelja isplativosti rada u Republici Sloveniji *137*
5.3. Komparativna analiza utjecaja uvedenih reformi na isplativost rada u Republici Hrvatskoj i Republici Sloveniji 142
6. ZAKLJUČAK 147
POPIS LITERATURE 153
POPIS TABLICA I SLIKA 161
POPIS KRATICA 165
ŽIVOTOPIS 167

1. UVOD

U disertaciji se analizira utjecaj sustava poreza i socijalnih naknada na isplativost rada u Republici Hrvatskoj i Republici Sloveniji, te se analizira potencijalno uvođenje politika za poboljšanje isplativosti rada na poticaje za rad u obje zemlje. U ovom poglavlju opisuju se predmet i ciljevi istraživanja, hipoteze i metodologija istraživanja, te znanstveni doprinos i struktura disertacije.

1.1. Predmet istraživanja

U raspravama akademske zajednice i političara o učinkovitosti sustava socijalne politike, jedna od glavnih točaka rasprave je utjecaj sustava socijalne skrbi na smanjenje sudjelovanja na tržištu rada, što povratno uzrokuje ovisnost takvih osoba o državi (Bejaković i sur., 2012). Naime, kod osoba izvan rada koje primaju naknade iz sustava socijalne skrbi ili naknadu za nezaposlenost, izdašnost navedenih novčanih transfera može stvoriti negativne poticaje za ulazak u svijet rada. Izdašni socijalni sustav može činiti rad manje atraktivnim, odnosno takav sustav ne potiče osobe izvan rada na aktivno traženje posla (Björklund i sur., 1991; Snower, 1997). U većini slučajeva prilikom zaposlenja takve osobe gube prava na ostvarivanje pojedinih naknada, te gube motiv za zapošljavanje ili dulji rad (Bejaković i sur. 2012).

Ključno pitanje u izradi sustava poreza i socijalnih naknada je kako napraviti ravnotežu između preraspodjele sredstava osobama s niskim dohotkom s jedne strane i održavanja snažnih poticaja za rad s druge strane (Figari, 2015). Bargain i Orsini (2006) navode kako je prilikom kreiranja socijalne politike primarni cilj pružati razinu dohotka koja bi osobama izvan rada osigurala minimalni životni standard, a da se pritom ne utječe previše negativno na poticaje za rad. Stoga je važno proanalizirati politike zapošljavanja „ranjivih“ skupina osoba izvan rada koje čine: dugotrajno nezaposlene osobe, parovi u kojima niti jedan supružnik ne radi, samohrani roditelji koji ne rade, te razmotriti potrebu uvođenja politika za poboljšanje isplativosti rada (engl. *make work pay policies*), koje će biti usmjerene na zaposlene ljude s nižim primanjima. Svrha uvođenja spomenutih politika za poboljšanje isplativosti je povećanje dohotka od slabije plaćenog rada i zapošljavanje dugotrajno nezaposlenih osoba čime bi se znatno smanjila isključenost „ranjivih“ skupina iz tržišta rada, te bi se posljedično smanjila sredstva koja država troši za programe socijalne zaštite spomenutih osoba.

Immervoll i Pearson (2009) navode kako su glavni ciljevi politika za povećanje isplativosti rada: (a) povećanje zaposlenosti kreiranjem dodatnih financijskih poticaja za ostankom u svijetu rada ili zapošljavanjem osoba s niskim primanjima i (b) povećanje prihoda financijski ugroženih radnika i njihovim obiteljima. Budući da je mogućnost primanja politika za povećanje isplativosti rada uvjetovana ponašanjem primatelja na tržištu rada, Immervoll i sur. (2007) navode kako su istraživanja pokazala da takve politike smanjuju neučinkovitost povezanu s tradicionalnim novčanim socijalnim naknadama. Nadalje, politike za povećanje isplativosti rada su i politički privlačne jer za razliku od drugih politika/naknada koje su uglavnom orijentirane prema ostvarivanju jednog zadanog cilja, one istovremeno postižu dva cilja: (1) utjecaj na povećanje zaposlenosti i (2) distribucijski učinak (Owens, 2006). Zbog toga su takve politike često u fokusu političke i akademske rasprave i uspjeh njihove implementacije ovisi o integraciji s postojećim sustavom poreza i socijalnih naknada i obilježjima tržišta rada (Figari, 2015).

Prve zemlje koje su uvele politike za povećanje isplativosti rada bile su SAD i Ujedinjeno Kraljevstvo (UK) koje su uvele EITC (engl. *Earned Income Tax Credit*) i WFTC (engl. *Working Family Tax Credit*). To je nadahnulo brojne europske zemlje da slijede isti primjer (Immervoll i Pearson, 2009), te je do sada više od polovice zemalja OECD-a uvelo politike za povećanje isplativosti rada koje se u svakoj zemlji razlikuju prema važnim obilježjima kao što su izdašnost, struktura politike i obuhvaćanje jedinica s niskim zaradama ili s niskim plaćama po satu (Figari, 2010). Tako se politike za povećanje isplativosti rada u većini zemalja dodjeljuju u obliku novčanih transfera, te kao odbitci od obveze poreza na dohodak i doprinosa za socijalna osiguranja. Međutim, najvažniji čimbenik prilikom postizanja ravnoteže između distribucijskih učinaka i poticaja za rad uzrokovanih politikama za povećanje isplativosti rada je odabir između obitelji ili pojedinca kao jedinice promatranja. Dakle, postoje dva tipa politika, obiteljski i individualni. Spomenute politike EITC i WFTC se dodjeljuju u obliku novčanih transfera koji se primaju uz provjeru dohotka obitelji, a obiteljski tip politike za povećanje isplativosti rada je ugrađen i u drugim zemljama poput Novog Zelanda, Kanade i Irske. Ipak, najveći dio empirijskih istraživanja proveden je na politikama uvedenim u UK-u i SAD-u (Eissa i Hoynes 2004; Blundell 2000). Pokazalo se kako politike koje se dodjeljuju uz provjeru dohotka obitelji imaju negativan utjecaj na isplativost rada prilikom zapošljavanja druge odrasle osobe u paru, dok je pozitivan utjecaj prisutan prilikom zapošljavanja prve osobe u paru. S druge strane, druga vrsta politika za povećanje isplativosti rada je orijentirana s obzirom na dohodak pojedinca i takve politike su

u zadnjim godinama postale popularne u kontinentalnoj Europi (Belgija, Finska, Mađarska, Nizozemska, Švedska) gdje su potencijalni negativni učinci obiteljski orijentiranih politika na drugog zaposlenika u paru potaknuli razvijanje individualiziranih politika (Immervoll i Pearson, 2009).

U Hrvatskoj se područje isplativosti rada tek nedavno počelo istraživati. Bejaković i sur. (2012) računali su participacijsku poreznu stopu (PPS; engl. *participation tax rate*) za osam hipotetskih tipova kućanstava. Analiza je pokazala kako određeni tipovi kućanstava poput samohranih roditelja i parova u kojima nijedan supružnik ne radi imaju vrlo visok PPS, dok je kod ostalih tipova PPS pretežno umjerene veličine. Bezeredi (2019) je također koristeći hipotetske podatke potvrdio rezultate prethodno spomenute analize te je na temelju komparativne analize sa zemljama EU-a otkrio kako se za navedene tipove kućanstva Hrvatska nalazi među zemljama s najvećim PPS-om. U Sloveniji do sada također postoje samo analize na hipotetskim podacima, a zadnju takvu analizu su izradili Laporšek i sur. (2019). Autori su zaključili kako Slovenija ima visok PPS u usporedbi sa zemljama OECD-a, te na temelju iskustava više od polovice zemalja OECD-a koje su uvele politike za povećanje isplativosti rada autori preporučaju uvođenje takvih politika u Sloveniju. Iako analize na hipotetskim kućanstvima mogu ukazati na problem visokog PPS-a za pojedine tipove kućanstava, takvi izračuni imaju svoje nedostatke jer ne daju pravu sliku stanja u nekoj zemlji. Stoga se u ovoj disertaciji analizira isplativost rada na stvarnim podacima te se otkriva realno stanje na području isplativosti rada u obje zemlje. Također, analizira se i potencijalno uvođenje odabranih politika za povećanje isplativosti rada kako bi se ispitalo kako takve politike mogu utjecati na povećanje isplativosti rada i smanjenje stope siromaštva u Hrvatskoj i Sloveniji. U obje zemlje se uvodi tip politike za povećanje isplativosti rada koji se u obliku novčanih transfera dodjeljuje zaposlenim osobama s niskim primanjima. Takav tip politike se u engleskoj literaturi naziva „*in-work benefit*“, a u ovoj disertaciji će se nazvati „*naknada za zaposlene*“.

Dakle, ovo je prva analiza isplativosti rada na stvarnim podacima u obje zemlje, a dodatno će se napraviti i komparativna analiza koja će otkriti kako na području isplativosti rada Hrvatska stoji u usporedbi sa susjednom zemljom EU-a. Naime, Slovenija je pogodna za usporedbu s Hrvatskom budući da su obje države nastale početkom devedesetih godina raspadom Jugoslavije, te imaju zajedničku prošlost. Slovenija je bila brža od Hrvatske na svom europskom putu, postala je država članica EU-a 2004. godine dok je Hrvatska u EU-u ušla 2013 godine, te je kao takva Slovenija vrlo korisna za usporedbu s Hrvatskom.

1.2. Ciljevi istraživanja

Temeljni cilj istraživanja je analizirati područje isplativosti rada u Republici Hrvatskoj i Republici Sloveniji. Može se podijeliti na nekoliko znanstvenih i aplikativnih ciljeva. Znanstveni ciljevi se mogu grupirati u nekoliko glavnih ciljeva i njihovih podciljeva:

1. Analizirati utjecaj postojećeg hrvatskog sustava poreza i socijalnih naknada na poticaje za rad u Republici Hrvatskoj;
   a. Procijeniti veličinu i distribuciju participacijske porezne stope prema različitim tipovima kućanstava;
   b. Procijeniti koje demografske i socio-ekonomske karakteristike imaju najveći utjecaj na visinu participacijske porezne stope;
   c. Procijeniti koji instrumenti sustava poreza i socijalnih naknada imaju najveći utjecaj na participacijsku poreznu stopu.

2. Predložiti mehanizme za ublažavanje zamki neaktivnosti, odnosno analizirati potencijalnu implementaciju politika za povećanje isplativosti rada na stopu siromaštva i isplativost rada u Republici Hrvatskoj;
   a. Implementirati dvije vrste naknada za zaposlene koje se spominju u literaturi, naknade uz provjeru dohotka obitelji i naknade uz provjeru dohotka pojedinaca;
   b. Analizirati i usporediti utjecaj uvedenih naknada za zaposlene na isplativost rada;
   c. Analizirati i usporediti utjecaj uvedenih naknada za zaposlene na distribuciju raspoloživog dohotka kućanstva i stopu siromaštva.

3. Analizirati područje isplativosti rada u Republici Sloveniji, te usporediti dobivene rezultate između Republike Hrvatske i Republike Slovenije;
   a. Analizirati utjecaj slovenskog sustava poreza i socijalnih naknada na isplativost rada u Republici Sloveniji;
   b. Predložiti odabrane tipove naknada za zaposlene i analizirati utjecaj na isplativost rada i stopu siromaštva u Republici Sloveniji;
   c. Usporediti stanje na području isplativosti rada između susjednih zemalja Republike Hrvatske i Republike Slovenije te utvrditi kako Republika Hrvatska stoji u usporedbi s Republikom Slovenijom.

Uz znanstvene, disertacija ima i aplikativne ciljeve koji se odnose na preporuke nositeljima ekonomske politike iz područja tržišta rada:

1. Predložiti kreatorima politike određeni smjer u kojem bi trebalo ići u svrhu dodatnog poboljšanja poticaja za rad u Republici Hrvatskoj;
2. Potaknuti korištenje mikrosimulacijskih modela u formuliranju poreznih politika i politika sustava socijalnih naknada.

1.3. Hipoteze istraživanja

Kako bi se stekla spoznaja o utjecaju sustava poreza i socijalnih naknada na isplativost rada u Republici Hrvatskoj, na temelju postavljenih ciljeva definirane su sljedeće hipoteze istraživanja i njihove pomoćne hipoteze:

H1: Razina prosječne participacijske porezne stope za osobe izvan rada u Republici Hrvatskoj je umjerena uz značajan postotak osoba s visokom i vrlo visokom participacijskom poreznom stopom.

H1a: Vjerojatnost vrlo visoke participacijske porezne stope za osobe izvan rada pada sa stupnjem njihova obrazovanja i s razinom tržišnog dohotka koji ostvaruju njihov supružnik i ostali članovi kućanstva, a raste s brojem maloljetne djece.

H1b: Republika Slovenija ima višu prosječnu participacijsku poreznu stopu i veći udio osoba izvan rada s visokom i vrlo visokom participacijskom poreznom stopom nego Republika Hrvatska.

H2: Naknada za zaposlene uz provjeru dohotka obitelji i naknada za zaposlene uz provjeru dohotka pojedinca imaju različite učinke na promjenu participacijske porezne stope pojedinih skupina osoba izvan rada.

H2a: Za najranjivije skupine naknada uz provjeru dohotka obitelji efikasnija je u smanjenju participacijske porezne stope nego naknada uz provjeru dohotka pojedinca.

H2b: Naknada uz provjeru dohotka obitelji povećava participacijsku poreznu stopu parova u kojima jedan supružnik radi.

H2c: Naknada uz provjeru dohotka pojedinca smanjuje participacijsku poreznu stopu svih skupina.

H3: Naknada za zaposlene uz provjeru dohotka obitelji efikasnija je u smanjenju stope siromaštva nego naknada za zaposlene uz provjeru dohotka pojedinca.

Obrazloženje hipoteza:

Prva hipoteza i njezine pomoćne hipoteze (H1; H1a, H1b): Prethodna istraživanja na hipotetskim kućanstvima u Hrvatskoj pokazala su kako određeni tipovi kućanstava poput samohranih roditelja i parova u kojima nijedan supružnik ne radi imaju vrlo visok PPS, dok je kod ostalih tipova PPS pretežno umjerene veličine (Bejaković i sur., 2012, Bezeredi, 2019). Budući da tipovi kućanstava koji su skloni visokom ili vrlo visokom PPS-u nisu prevladavajući tipovi u populaciji, očekuje se kako će u prosjeku PPS u Hrvatskoj biti umjerene veličine, uz postojanje osoba s visokim ili vrlo visokim PPS-om. PPS ispod 50% smatra se umjerenim, između 50 i 70% smatra se visokim, dok se PPS iznad 70% smatra vrlo visokim.

Nadalje, testiranjem pomoćne hipoteze H1a nastoji se utvrditi koja demografska i socio-ekonomska obilježja utječu na vjerojatnost vrlo visokog PPS-a. Očekuje se kako vjerojatnost vrlo visokog PPS-a osoba izvan rada pada s povećanjem stupnja obrazovanja i s povećanjem tržišnog dohotka (uključujući i mirovine) koji ostvaruju njihov supružnik i ostali članovi kućanstva, a raste s brojem maloljetne djece. Naime, u radu Bezeredi i Urban (2016) pokazano je kako s povećanjem stupnja obrazovanja raste plaća koju osoba može ostvariti na tržištu rada što posljedično smanjuje PPS, a time i vjerojatnost vrlo visokog PPS-a. Porast tržišnog dohotka (uključujući i mirovine) supružnika i ostalih članova kućanstva povećava raspoloživi dohodak kućanstva kojemu pripada promatrana osoba izvan rada. S povećanjem raspoloživog dohotka kućanstva smanjuje se iznos socijalnih naknada (dok potpuno ne iščezne), čime pada i vjerojatnost vrlo visokog PPS-a. S druge strane, broj maloljetne djece povećava potencijalni iznos socijalnih naknada koje osoba izvan rada može ostvariti, a s porastom socijalnih naknada raste i vjerojatnost visokog PPS-a.

U svrhu međunarodne usporedbe testira se hipoteza H1b kojom se nastoji utvrditi ima li Slovenija viši prosječni PPS i veći udio osoba izvan rada s visokim i vrlo visokim PPS-om nego Hrvatska. Naime, Slovenija ima izdašniji sustav socijalnih naknada od Hrvatske, a u radu Urban i sur. (2019) je utvrđeno kako Slovenija ima veće porezno opterećenje dohotka od rada, te se očekuje da je isplativost rada veći problem u Sloveniji nego u Hrvatskoj.

Druga hipoteza i njezine pomoćne hipoteze (H2; H2a, H2b, H2c): Velikodušni sustavi socijalnih naknada u većini zemalja EU-a smanjuju poticaje za rad što je potaknulo više od polovine zemalja EU-u na uvođenje politika za povećanje isplativosti rada (Bargain i Orsini, 2006). Budući da ne postoji opći konsenzus oko dizajna optimalne politike za povećanje isplativosti rada i da učinkovitost implementacije politika ovisi o njihovoj integraciji s

postojećim sustavom poreza i socijalnih naknada i obilježjima tržišta rada (Figari, 2015), u ovoj hipotezi se testiraju učinci dviju vrsta politika za povećanje isplativosti rada na poticaje za rad. Uvodi se tip politike za povećanje isplativosti rada koji se u obliku novčanih transfera dodjeljuje zaposlenim osobama s niskim primanjima. Takav tip politike se u ovoj disertaciji naziva „*naknada za zaposlene*“, dok se u engleskoj literaturi naziva „*in-work benefit*“. Nadalje, obje vrste naknada za zaposlene su definirane tako da su glavna obilježja svake naknade preuzeta iz britanskog WTC-a (engl. *Working Tax Credit*), a razlika između njih je ta što se prva naknada provjerava s obzirom na dohodak obitelji, dok se druga provjerava s obzirom na dohodak pojedinca. U smislu uvedene naknade uz provjeru dohotka obitelji, obitelj čine supružnici i njihova djeca do 18 godina.

Kako su naknade uz provjeru dohotka obitelji više usmjerene na siromašnija kućanstva, odnosno na kućanstva gdje niti jedan odrasli član u obitelji ne radi, očekuje se da će, za razliku od naknada uz provjeru dohotka pojedinca, takve naknade biti efikasnije u smanjenju PPS-a najranjivijih skupina koje čine samohrani roditelji i parovi gdje niti jedan odrasli član ne radi. Budući da su oba tipa naknada definirana uz iste ukupne troškove, hipotezom H2a se testira koja je od spomenutih naknada efikasnija u smanjenju PPS-a najranjivijih skupina (skupina s najvećom razinom PPS-a u populaciji).

Nadalje, očekuje se da će naknada uz provjeru dohotka obitelji imati negativan utjecaj na isplativost rada parova u kojima jedan supružnik radi. U slučaju kada jedan supružnik već radi i prima naknadu, zaposlenje drugog supružnika može povećati razinu ukupnog dohotka obitelji tako da takva obitelj više nema pravo na naknadu za zaposlene što povratno djeluje na povećanje PPS-a. Stoga se hipotezom H2b testira povećava li naknada za zaposlene uz provjeru dohotka obitelji PPS parova u kojima jedan supružnik radi.

S druge strane, naknada uz provjeru dohotka pojedinca uzima u obzir samo dohodak promatrane osobe, te se očekuje kako će ta naknada smanjivati PPS svih skupina ljudi, što se testira s hipotezom H2c.

Treća hipoteza (H3): Glavni cilj ove hipoteze je utvrditi utjecaj uvedenih naknada za zaposlene na smanjene stope siromaštva, odnosno usporediti efikasnost uvedenih naknada u smanjenju stope siromaštva. Naknade za zaposlene su po svojoj definiciji usmjerene na siromašnu radnu populaciju i kao takve se u zemljama južne Europe često koriste i kao sredstvo pomoći za značajan udio siromašne radne populacije (Figari, 2010). Dakle, takve se politike, uz svoju

primarnu zadaću koja je poboljšanje isplativosti rada, dodatno koriste i u svrhu smanjenja stope siromaštva zaposlenih, a time i cjelokupne populacije. Kako su druge naknade općenito usmjere prema ostvarivanju jednog zadanog cilja, istovremeno postizanje spomenuta dva cilja je ono što naknade za zaposlene čini politički privlačnima (Owens, 2006). Budući da naknade uz provjeru dohotka obitelji uzimaju u obzir primanja uže obitelji koju čine supružnici i njihova djeca do 18 godina, takve naknade bi trebale biti usmjerenije na siromašnije obitelji od naknada uz provjeru dohotka pojedinca. Kako su obje naknade uvedene uz iste troškove, ovom hipotezom se utvrđuje jesu li naknade uz provjeru dohotka obitelji efikasnije u smanjenju stope siromaštva nego naknade uz provjeru dohotka pojedinca i u kojoj mjeri su efikasnije.

1.4. Metode istraživanja

Disertacija će se zasnivati na teorijskoj i empirijskoj analizi. U istraživanju će se od standardnih metoda za izradu znanstveno istraživačkog rada primjenjivati deskriptivna metoda, metoda analize i sinteze, komparativna metoda, klasifikacijska metoda, mikrosimulacijske metode, te statističke i ekonometrijske metode. U teorijskom dijelu istraživanja opisuje se predmet istraživanja, dok se metodama analize i sinteze proučavaju postojeća znanja i spoznaje o problemu istraživanja dostupne u znanstvenoj i stručnoj literaturi u zemlji i inozemstvu.

U empirijskom dijelu analize koja se provodi za Hrvatsku i Sloveniju, prvo će se deskriptivnom metodom analizirati osnovne karakteristike podataka, odnosno varijabli korištenih u istraživanju. Za Hrvatsku se koriste podaci iz Ankete o dohotku stanovništva (ADS) za 2016. koju provodi Državni zavod za statistiku, dok se za Sloveniju koriste podaci iz EU-SILC ankete (engl. Statistics on Income and Living Conditions) za 2016. EU-SILC je istraživanje koje je obvezno za sve zemlje EU-a, a provodi se redovito na godišnjoj razini. ADS je usklađen s metodologijom Eurostata koja se primjenjuje za istraživanja EU-SILC, pa su podaci iz ove dvije ankete usporedivi. Razlog korištenja ADS-a za Hrvatsku umjesto EU-SILC ankete leži u činjenici da ADS sadrži detaljnije podatke nego EU-SILC anketa.

Najvažniji alat koji se koristi u dokazivanju ili opovrgavanju svih hipoteza (**H1**, **H2** i **H3**) su mikrosimulacijske metode. Za Hrvatsku se koristi miCROmodA –mikrosimulacijski model hrvatskih poreza i socijalnih naknada koji se temelji na hrvatskom modulu EUROMOD-a (Urban i sur., 2018b), dok se za Sloveniju koristi slovenski modul EUROMOD-a (Kump i sur, 2018). EUROMOD je mikrosimulacijski model poreza i socijalnih naknada za zemlje Europske unije koji se koristi za procjenu utjecaja direktnih poreza, doprinosa za socijalno osiguranje i socijalnih naknada na raspoloživi dohodak kućanstva i isplativost rada, te omogućuje

usporedbu između zemalja EU-a. Glavna prednost EUROMOD-a je što uključuje module za sve zemlje EU-a unutar istog metodološkog okvira što omogućuje fleksibilnost analize i usporedivost rezultata (Sutherland i Figari, 2013). miCROmodA se može ukratko definirati kao EUROMOD-ov „spin-off" model, koji u odnosu na EUROMOD dodatno omogućuje simuliranje poreza i socijalnih naknada na regionalnoj i lokalnoj razini u Hrvatskoj, a razvijen je u okviru HRZZ projekta (UIP-09-2014-4096), koji je proveden na Institutu za javne financije. Dodatna prednost je što za razliku od hrvatskog modula Euromod-a koji koriste podatke iz EU-SILC ankete, miCROmodA koristi podatke iz ADS-a koji su detaljniji. Slovenski modul EUROMOD-a koristi podatke iz EU-SILC ankete za Sloveniju. U mikrosimulacijske modele su ugrađena pravila iz hrvatskog i slovenskog sustava poreza i socijalnih naknada koja su vrijedila na dan 30. lipnja 2017. Dohodovne varijable iz anketa (ADS 2016 i EU-SILC 2016) se odnose na stanje u 2015., te su dodatno prilagođene na razinu iz 2017. korištenjem koeficijenata prilagodbe zasnovanih na službenoj statistici.

Za dokazivanje ili opovrgavanje hipoteza **H1** i **H2** potrebno je dodatno procijeniti PPS koji se koristi kao glavni pokazatelj isplativosti rada. PPS se računa za osobe izvan rada koje čine nezaposlene i neaktivne osobe – žene u dobi od 18 do 60 i muškarci od 18 do 65 godina. Pod neaktivnim osobama u ovoj analizi smatraju se osobe koje obavljaju kućanske poslove i brinu se o kućanstvu, dok ostale skupine koje se ponekad nazivaju neaktivnima (osobe u obrazovanju, umirovljenici, nesposobni za rad, itd.) nisu predmet ove analize. Općenito, u literaturi se PPS ispod 50% smatra umjerenim, između 50 i 70% smatra se visokim, dok se PPS veći ili jednak 70% smatra vrlo visokim.

PPS mjeri udio zarade koji osoba gubi zbog smanjenja iznosa socijalnih naknada ili povećanja poreza i socijalnih doprinosa pri prelasku iz stanja nezaposlenosti ili neaktivnosti u stanje zaposlenosti. Metodologija izračuna realnog PPS-a temelji se na tranziciji osoba koje su u stvarnosti (prema podacima) izvan rada u hipotetsko stanje zaposlenosti, te izračuna stvarnog i hipotetskog raspoloživog dohotka koristeći mikrosimulacijske modele. Kako bi se za osobu izvan rada izračunao raspoloživi dohodak u hipotetskom stanju zaposlenosti, potrebno je predvidjeti njezinu bruto plaću. Za predviđanje bruto plaće koristi se Heckmanov selekcijski model (Heckman, 1976; Heckman, 1979; Wooldridge, 2002; Breunig i Mercante, 2010) koji identificira i uklanja problem odabira uzorka (engl. *sample selection problem*) i kojeg istraživači uobičajeno koriste za predviđanje plaća osoba izvan rada (Bargain i Orsini, 2006; Bargain i sur., 2010; O'Donoghue, 2011). Uz spomenute metode, u hipotezi **H1a** se logit

modelom procjenjuje utjecaj odgovarajućih demografskih i socioekonomskih obilježja na vjerojatnost vrlo visokog PPS-a.

Za dokazivanje ili opovrgavanje hipoteze **H2** potrebno je u mikrosimulacijske modele za Hrvatsku i Sloveniju implementirati odabrane politike za povećanje isplativosti rada, te nakon toga ponovno procijeniti PPS za osobe izvan rada kako bi se utvrdio utjecaj implementiranih reformi na isplativost rada. Implementiraju se dvije vrste naknada za zaposlene (dvije reforme) koje su preuzete iz UK-a gdje se takva naknada zove „Working tax credit“ (WTC), a namijenjene su zaposlenim osobama s niskim primanjima i dodjeljuju se u obliku novčanih transfera. Zadržat će se osnovna obilježja spomenutih politika, no uvode se razne prilagodbe i pojednostavljenja. U stvarnosti se pravo na primanje WTC-a provjerava prema dohotku obitelji. U ovom istraživanju će se originalni WTC modificirati tako da će u prvoj reformi ta naknada biti provjeravana prema dohotku obitelji (naziv naknade WTC-FAM), dok će u drugoj biti provjeravana s obzirom na dohodak pojedinaca (naziv naknade WTC-IND). Naknade WTC-FAM i WTC-IND su kalibrirane tako da su im jednaki ukupni troškovi uvođenja, kako bi se uz iste troškove mogla usporediti efikasnost pojedine reforme. Efikasnijom reformom smatra se ona koja uz iste troškove daje bolje rezultate u smislu smanjenja PPS-a.

Za testiranje hipoteze **H3** prvo se mikrosimulacijskim modelima računa raspoloživi dohodak kućanstava u Hrvatskoj i Sloveniji na temelju stvarnog scenarija, a nakon toga se računa raspoloživi dohodak uz uvedene naknade za zaposlene (WTC-FAM i WTC-IND). Stopa siromaštva se računa na standardnoj liniji siromaštva od 60% medijana ekvivalentnog raspoloživog dohotka kućanstva, a komparativnom metodom se utvrđuje koja je od uvedenih naknada, uz iste troškove, efikasnija u smanjenju stope siromaštva u svakoj od promatranih zemalja. U svakom od reformskih scenarija se prilikom izračuna stope siromaštva koristi fiksni prag siromaštva, koji se izračunava prema ekvivalentnom raspoloživom dohotku kućanstva dobivenom u stvarnom scenariju

1.5. Očekivani znanstveni doprinos

U Hrvatskoj se područje isplativosti rada tek nedavno počelo konkretnije istraživati. Bejaković i sur. (2012) i Bezeredi (2019) računali su PPS za odabrane tipove hipotetskih kućanstava. Za Sloveniju, kao i za Hrvatsku, postoji samo analiza isplativosti rada na temelju hipotetskih podataka koju su proveli Laporšek i sur. (2019). Iako takve analize mogu ukazati na problem visokog PPS-a za pojedine tipove kućanstava, izračuni na hipotetskim podacima ne daju pravu sliku stanja u nekoj zemlji. Hipotetski primjeri mogu otkriti koji tipovi kućanstava imaju visok

PPS, ali ne otkrivaju koliko ima takvih kućanstava, odnosno ne otkrivaju je li visok PPS doista ozbiljan problem u Hrvatskoj. Budući da se u ovoj disertaciji koriste stvarni podaci, znanstveni doprinos se očituje u dobivanju novih spoznaja o isplativosti rada na stvarnim (anketnim) podacima u Hrvatskoj i Sloveniji čime se otkriva prava slika stanja u tim zemljama, što je prvo takvo istraživanje. Znanstvenim doprinosom smatra se i dobivanje spoznaje o tome koje „specifične grupe" ljudi izvan rada u Hrvatskoj i Sloveniji (npr. osobe s nižim stupnjem obrazovanja, samohrani roditelji, parovi gdje niti jedan odrasli član ne radi, itd.) imaju slabe poticaje za ulazak u svijet rada (visok PPS), što se dobiva distribucijom PPS-a prema određenim demografskim i socio-ekonomskim karakteristikama. Dodatno, po prvi puta se otkriva koje komponente sustava poreza i socijalnih naknada najviše utječu na visinu PPS-a u tim zemljama što se dobiva dekompozicijom PPS-a prema odabranim elementima poreznog i socijalnog sustava.

Nadalje, budući da se u Hrvatskoj i Sloveniji do sada nije analiziralo uvođenje politika za povećanje isplativosti rada, znanstveni doprinos disertacije očituje se i u prvoj analizi potencijalne implementacija politika za povećanje isplativosti rada u hrvatski i slovenski sustav poreza i socijalnih naknada, čime se otkriva kako spomenute politike utječu na isplativost rada i stopu siromaštva.

Disertacija također daje doprinos u području komparativne analize stanja na području isplativosti rada između Hrvatske i Slovenije.

1.6. Struktura disertacije

U **uvodnom dijelu** se ukratko opisuje problem i tema istraživanja, odnosno značaj doktorske disertacije u odnosu na dosadašnja istraživanja. Definira se područje i predmet istraživanja, navode se istraživački i aplikativni ciljevi koji se žele postići, te hipoteze koje će se testirati u ovoj disertaciji. Potom se opisuju metode znanstvenog istraživanja koje će se koristiti prilikom testiranja definiranih hipoteza. Na kraju se opisuje očekivani znanstveni doprinos, a uvodni dio završava kratkim opisom strukture doktorske disertacije.

Drugo poglavlje započinje komparativnim pregledom tržišta rada između Hrvatske i zemalja Europske unije koristeći podatke Eurostata. Prvo se analiziraju stope zaposlenosti, nezaposlenosti, dugotrajne nezaposlenosti i neaktivnosti, te se analizira kako Hrvatska stoji u usporedbi s zemljama EU-a kao i s prosjekom EU28. Također, analizira se i koliko je Hrvatska udaljena od ciljane stope zaposlenosti populacije u dobi od 20 do 64 godine od najmanje 75% koju je Europska komisija (2010) u strategiji *Europe 2020* navela kao jedan od ciljeva koje bi

Europska unija trebala postići do 2020. Potom se analiziraju potencijalno zapošljive osobe izvan rada (PZOIR) i potencijalna radna snaga. PZOIR skupina ljudi (nezaposleni, osobe koje obavljaju kućanske poslove i brinu se o kućanstvu, osobe koje smatraju da nema adekvatnog posla za njih) je ujedno i predmet analize ove disertacije. U ovom dijelu disertacije prezentirati će se osnovni statistički podaci o tome koliko ima takvih osoba u Hrvatskoj i zemljama EU-a. Komparativni pregled završava analizom troškova socijalne zaštite i stope siromaštva. Poglavlje se nastavlja definiranjem koncepta i mjerenja isplativosti rada, te se daje pregled dosadašnjih istraživanja utjecaja sustava poreza socijalnih naknada na isplativost rada. Poglavlje završava pregledom politika za povećanje isplativosti rada koje će se analizirati u ovoj disertaciji, a te politike su nazvane naknade za zaposlene. Spominju se dva tipa naknada, naknade uz provjeru dohotka obitelji i uz provjeru dohotka pojedinca. Navode se prednosti i nedostaci oba tipa naknada, kao i rezultati dosadašnjih istraživanja u kojima se analizirao utjecaj uvođenja spomenutih naknada na isplativost rada.

Treće poglavlje započinje definiranjem pokazatelja isplativosti rada koji će se procjenjivati u sljedećim poglavljima. Definira se PPS koji je ujedno i najčešće korišteni pokazatelj isplativosti rada u literaturi. Dodatno, u svrhu usporedbe definira se i drugi pokazatelj isplativosti rada, neto stopa zamjene (NSZ, engl. *net replacement rate*), koja se također koristi u literaturi, ali rjeđe nego PPS. Nakon toga definiraju se regresijski modeli koji će se koristiti u analizi: Heckmanov selekcijski model i logit model. Heckamnov selekcijski model koristi se za predviđanje plaća osoba izvan rada (PZOIR skupina ljudi) u hipotetskom slučaju kada bi se takve osobe zaposlile, a logit model će se koristiti kako bi se utvrdilo koja demografska i socio-ekonomska obilježja imaju utjecaj na vjerojatnost vrlo visokog PPS-a. Poglavlje se nastavlja analizom korištenih podataka iz Ankete o dohotku stanovništva za Hrvatsku i EU-SILC ankete (engl. *Statistics on Income and Living Conditions*) za Sloveniju. Definiraju se varijable korištene u analizi, te se provodi njihova deskriptivna analiza za Hrvatsku i Sloveniju. Zatim se predviđaju plaće za osobe izvan rada koje će se koristiti prilikom izračuna PPS-a, te se analizira koje odrednice najviše utječu na visinu plaće u spomenute dvije zemlje. Poglavlje završava definiranjem mikrosimulacijskih modela poreza i socijalnih naknada EUROMOD-a i *miCROmod*-a kojima se računa raspoloživi dohodak, te iznos primljenih socijalnih naknada i plaćenih poreza.

U **četvrtom poglavlju** se analizira isplativost rada u Hrvatskoj i Sloveniji, a poglavlje počinje analizom isplativosti rada u Hrvatskoj. Opisuje se postojeći sustav poreza i socijalnih naknada u Hrvatskoj koji je ugrađen u mikrosimulacijski model *miCROmod*. Potom se analizira PPS za odabrane tipove hipotetskih kućanstava kako bi se ilustriralo koji „specifični“ tipovi kućanstava

imaju niske, a koji visoke poticaje za ulazak u svijet rada. Nakon analize hipotetskih kućanstava slijedi empirijska analiza isplativosti rada u Hrvatskoj koja na temelju realnih podataka iz ADS-a otkriva je li isplativost rada, odnosno jesu li niski poticaji za ulazak u svijet rada ozbiljni problem u Hrvatskoj. Analiza otkriva koje karakteristike pojedinaca najviše utječu na visinu PPS-a, odnosno koja obilježja pojedinaca su glavni uzročnici visokog PPS-a. Nakon analize isplativosti rada u Hrvatskoj, slična analiza se provodi i za Sloveniju. Definira se postojeći sustav poreza i socijalnih naknada u Sloveniji, te se analizira PPS na hipotetskim i stvarnim podacima iz EU-SILC-a. Poglavlje završava komparativnom analizom područja isplativosti rada u Hrvatskoj i Sloveniji. Uspoređuju se pokazatelji isplativosti rada za odabrane tipove hipotetskih kućanstava, kao i pokazatelji dobiveni na temelju realnih podataka, čime se utvrđuje koja od promatranih zemalja ima veće poticaje za ulazak u svijet rada.

U **petom poglavlju** analizira se utjecaj uvođenja odabranih politika za povećanje isplativosti rada na stopu siromaštva i isplativost rada u Hrvatskoj i Sloveniji. Budući da je više od polovice zemalja OECD-a uvelo odabrane politike za povećanje isplativosti rada u svoj sustav poreza i socijalnih naknada, a Hrvatska i Slovenija nisu, u ovom poglavlju analizira se utjecaj uvođenja spomenutih politika na isplativost rada u obje zemlje. Definiraju se dva tipa politika za povećanje isplativosti rada koje su nazvane naknade za zaposlene (naknade uz provjeru dohotka obitelji i naknade uz provjeru dohotka pojedinca) i koje će se implementirati u hrvatski i slovenski sustav poreza i socijalnih naknada. Kako se naknade za zaposlene dodjeljuju zaposlenim osobama s niskim primanjima, prvo se analizira utjecaj njihovog uvođenja na smanjenje stope siromaštva i raspodjelu dohotka. Potom se utvrđuje kako pojedini tip uvedene naknade za zaposlene utječe na isplativost rada u svakoj zemlji, odnosno analizira se koji tip naknade je pogodniji za uvođenje u pojedinu zemlju. Na kraju poglavlja prezentiraju se rezultati komparativne analize utjecaja naknada za zaposlene na isplativost rada između Hrvatske i Slovenije, te se analizira u kojoj zemlji pojedini tipovi naknada, uz iste realne troškove u svakoj zemlji, jače djeluju na smanjenje PPS-a.

U **zaključku** se sustavno formuliraju i prezentiraju najvažniji empirijski rezultati dobiveni u istraživanju, utvrđuje se istinitost postavljenih hipoteza, te se navode ograničenja istraživanja.

Nakon zaključka navodi se popis literature, tablica, slika i kratica.

2. TRŽIŠTE RADA I ISPLATIVOST RADA

Poglavlje se sastoji od dva dijela. U prvom dijelu se provodi statistička analiza tržišta rada i siromaštva u Republici Hrvatskoj i zemljama Europske unije koristeći podatke Eurostata. U nastavku poglavlja definira se koncept i mjerenje isplativosti rada, daje se pregled dosadašnjih istraživanja u polju isplativosti rada i pregled politika koje se koriste u svrhu povećanja isplativosti rada.

2.1. Komparativni pregled tržišta rada i siromaštva u Republici Hrvatskoj i Europskoj uniji

Poglavlje počinje komparativnim pregledom stanja na tržištu rada u Republici Hrvatskoj i zemljama članicama Europske unije. Analizira se radno aktivna populacija, uspoređuju se stope zaposlenosti, nezaposlenosti, dugotrajne nezaposlenosti i stope neaktivnosti te se ukratko analizira siromaštvo u Hrvatskoj koristeći kao pokazatelj stopu rizika od siromaštva.

Aktivnu populaciju čine zaposlene i nezaposlene osobe. Nezaposlene su osobe koje trenutno ne rade, ali aktivno traže posao. Neaktivne osobe također su izvan rada, ali nisu uključene u aktivno traženje posla te nisu raspoložive za posao ili ga nisu spremne prihvatiti unutar određenog vremenskog perioda. Prema Eurostatovoj metodologiji pod neaktivne osobe ubrajaju se: (1) umirovljenici; (2) osobe nesposobne za rad; (3) učenici, studenti i osobe na osposobljavanju; (4) osobe koje obavljaju kućanske poslove i brinu se o kućanstvu; (5) osobe koje smatraju da nema adekvatnog posla za njih; te (6) ostale neaktivne osobe. Budući da svi navedeni tipovi neaktivnih osoba nemaju jednak potencijal za zapošljavanje, po uzoru na rad Nestić i Tomić (2018) neaktivne osobe dijele se na one koje su potencijalno zapošljive (grupe 4 do 6) i na osobe koje imaju određeni pravni razlog za ostati izvan rada (grupe 1 do 3). Tako potencijalno zapošljive neaktivne osobe (PZNO) zajedno s nezaposlenim osobama čine skupinu potencijalno zapošljivih osoba izvan rada (PZOIR).[1]

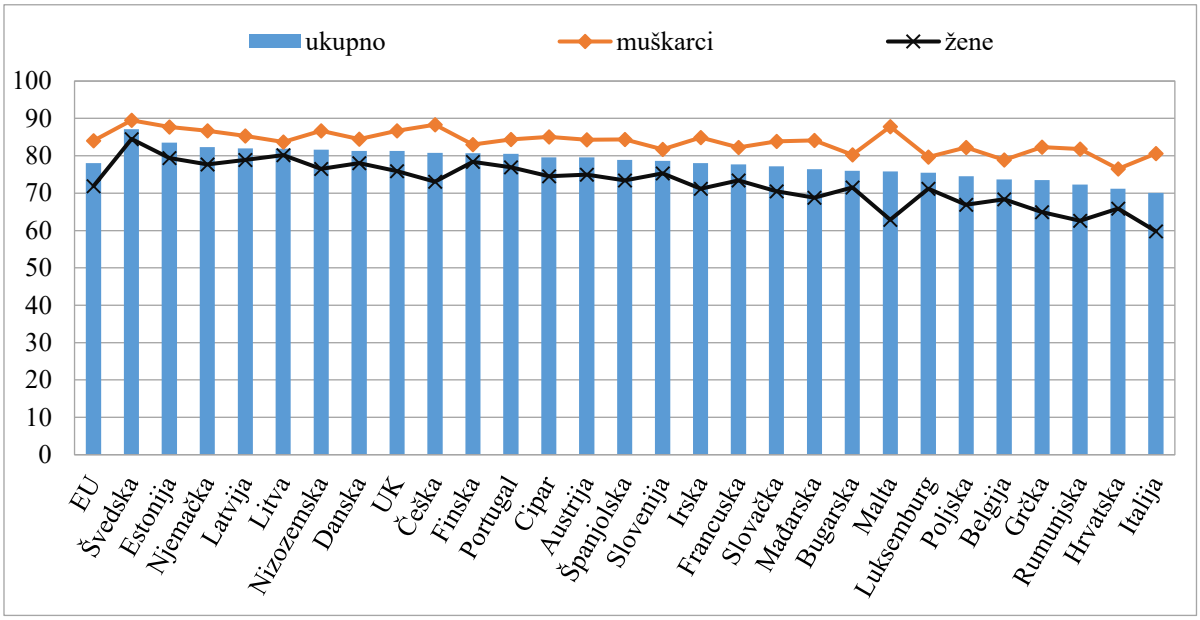
2.1.1. Pregled zaposlenosti, nezaposlenosti i neaktivnosti

U 2017. Hrvatska je imala jednu od najnižih stopa aktivnosti unutar EU-a za populaciju u dobi od 20 do 64 godine.[2] Stopa aktivnosti iznosila je 71,2%, što je za oko 7 postotnih bodova

[1] Skupina PZIOR je po svojoj definiciji jednaka skupini „NEET adults“ koja je definirana u radu Nestić i Tomić (2018).

[2] Stopa aktivnosti se definira kao postotni udio aktivne u radno sposobnoj populaciji. U ovom dijelu se u aktivnu populaciju ubrajaju zaposlene i nezaposlene osobe u dobi od 20 do 64 godine, a u radno sposobnu populaciju se ubrajaju sve osobe u dobi od 20 do 64 godine.

niže od prosjeka EU-a, a Italija je jedina zemlja unutar EU-a koja ima nižu stopu aktivnosti od Hrvatske (slika 2.1.). Razlika u stopi aktivnosti između spolova u Hrvatskoj iznosi oko 11 postotnih bodova. Preciznije, uzmu li se u obzir samo žene, stopa aktivnosti iznosi 65,9% (što je za 6 postotnih bodova niže od prosjeka EU-a), a iza Hrvatske se nalaze Grčka, Malta, Rumunjska i Italija. Nadalje, Hrvatska ima najnižu stopu aktivnosti muškaraca unutar EU-a koja iznosi 76,5% (7,5 postotnih bodova niže od prosjeka EU-a). Švedska je zemlja s najvećom stopom aktivnosti, koja iznosi 87%, a ujedno ta zemlja ima i najveću stopu aktivnosti muškaraca (89,5%) i žena (84,5%) unutar EU-a.



Slika 2.1. Stopa aktivnosti u 2017. za populaciju u dobi od 20 do 64 godine prema spolu, %
Izvor: Eurostat, anketa o radnoj snazi (lfsa_argan)

Hrvatska bilježi nisku fluktuaciju u stopi aktivnosti. Tako je u 2008. stopa aktivnosti iznosila 70,6% i bila je skoro identična onoj u 2017. Najniža stopa aktivnosti zabilježena je u 2012. (68,7%)%, najviša 2015. (71,8%).

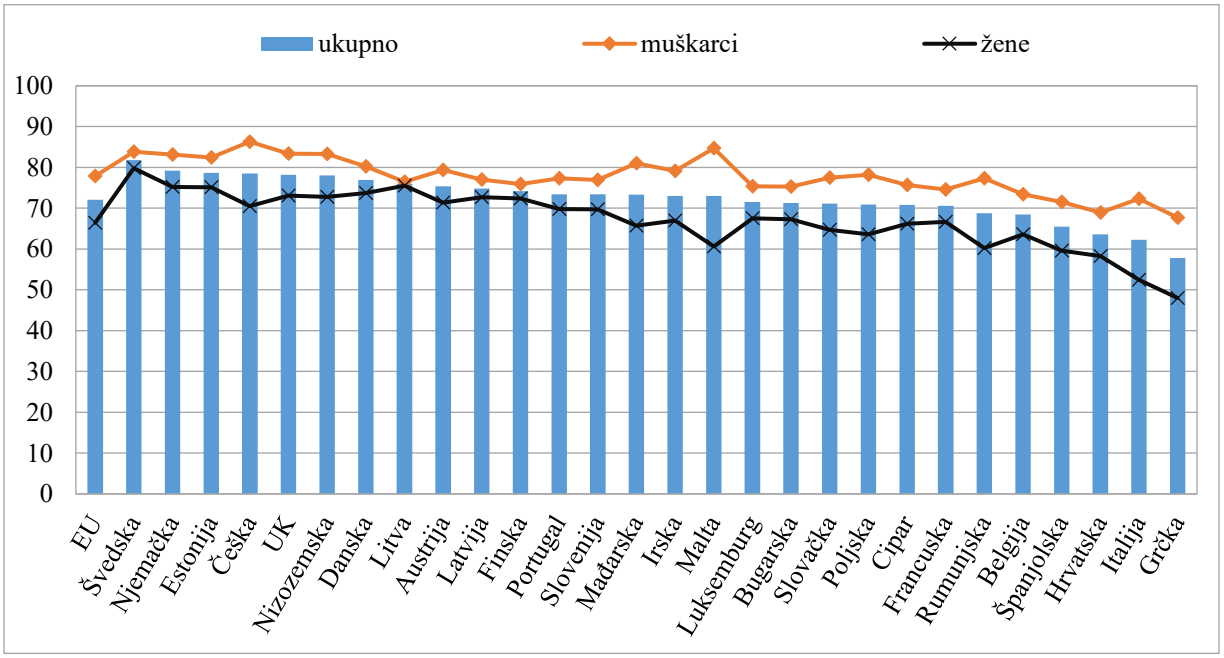
Zaposlena populacija

Niske stope zaposlenosti obilježavaju tržišta rada u mnogim zemljama jugoistočne Europe (Nestić i Tomić, 2018). Budući da su niske stope zaposlenosti ujedno i jedan od čimbenika koji ograničava gospodarski rast zemlje njihova analiza zaslužuje posebnu pozornost (Tomić, 2015). Gregurić (2011) u svojem osvrtu na dokument *Europe 2020*, u kojem Europska komisija (2010) opisuje desetogodišnju strategiju za pametan, održiv i uključiv razvoj, navodi kako će se u tom razdoblju Europljani susretati s mnogim izazovima. Negativne demografske promjene utjecat će na smanjenje radno aktivnog i povećanje uzdržavanog stanovništva, a dio

radno aktivnog stanovništva nema zadovoljavajuće radne sposobnosti kako bi sudjelovali na tržištu rada. Dodatno, Gregurić (2011) navodi kako su nezaposlene osobe posebno rizična skupina koja vrlo lako može upasti u siromaštvo, a za rješenje spomenutih problema potrebno je provesti određene reforme tržišta rada i socijalnog sustava. Stoga, Europska komisija (2010) u strategiji *Europe 2020* navodi kako postoji opći konsenzus oko činjenice da se EU treba usuglasiti oko ograničenog broja glavnih ciljeva koje treba postići do 2020. Tako je jedan od pet ciljeva koje bi EU trebala postići do 2020. bio dostizanje stope zaposlenosti za stanovništvo u dobi 20-64 od najmanje 75%, dodatno uzimajući u obzir veću uključenost žena, starijih radnika i migranata u radnu snagu. Dostizanjem planirane stope zaposlenosti od 75% na razini EU-a nastoji se potaknuti gospodarski rast čime bi se smanjili socijalni rizici i negativni utjecaji na javne financije koji se povezani s problemom starenja stanovništva (Europska komisija, 2017a). Nadalje, u spomenutom članku Europske komisije (2017a), koji se bavi problematikom žena na tržištu rada, kao ključni element u postizanju ciljane zaposlenosti od 75% unutar EU-a navodi se povećanje zaposlenosti žena. Spomenuta činjenica temelji se na istraživanju Cuberes i Teignier (2016), u kojem je procijenjeno kako rodne nejednakosti na tržištu rada u Europi uzrokuju niži BDP po stanovniku do 10%. S druge strane, u dokumentu *Nacionalni program reformi 2018.,* Vlada RH (2018) je kao cilj za 2020. postavila dostizanje stope zaposlenosti od relativno skromnih 65,2%, što je za oko 10 postotnih bodova niže od prosjeka EU-a.

Što se tiče stvarnog stanja u 2017., uspoređujući stope zaposlenosti sa zemljama EU-a u dobi od 20 do 64 godine, slika 2.2. prikazuje kako je Hrvatska među zemljama s najnižom stopom zaposlenosti. Tako je stopa zaposlenosti iznosila 63,6%, što je za 8,5 postotnih bodova ispod prosjeka EU-a, a jedino su Italija i Grčka lošije od Hrvatske. Uzimajući u obzir stvarno stanje u 2017. i planirana stanja za 2020., prosječna stopa zaposlenosti EU-a u 2017. je za oko 3 postotna boda niža od planirane stope za 2020. najavljene u dokumentu *Europa 2020*, dok je Hrvatska u 2017. zaostajala za nešto više od 11 postotnih bodova za planiranim prosjekom EU-a u 2020. Međutim, što se tiče planirane stope zaposlenosti za 2020. od strane Vlade RH, Hrvatska je u 2017. bila za oko 2 postotna boda ispod te stope. Zemlje s najvišom stopom zaposlenosti unutar EU-a u 2017. bile su Švedska (oko 82%) i Njemačka (oko 79%), što je za 18, odnosno 15 postotnih bodova više od Hrvatske. Što se tiče susjednih zemalja, Hrvatska ozbiljno zaostaje za zemljama poput Mađarske i Slovenije, budući da je u tim zemljama stopa zaposlenosti veća za čak 10 postotnih bodova, što znači da su te zemlje već u 2017. bile za nešto manje od 2 postotna boda ispod prosjeka EU-a planiranog za 2020.

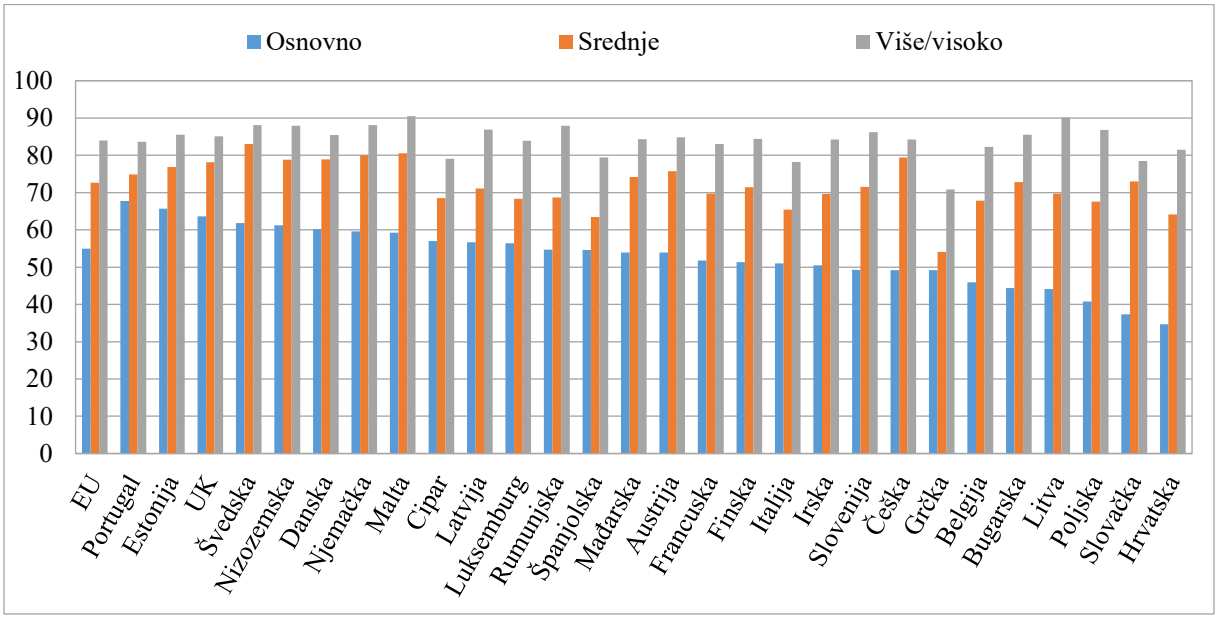
Promatra li se stopa zaposlenosti prema spolu, pokazalo se da postoji jaz između stopa zaposlenosti muškaraca i žena, koji u Hrvatskoj iznosi 16,4 postotnih bodova, dok na razini EU-a žene imaju za 11,5 postotnih bodova nižu stopu zaposlenosti od muškaraca (slika 2.2.). Stopa zaposlenosti žena u Hrvatskoj iznosi 58,3%, što je za oko 8 postotnih bodova ispod prosjeka EU-a za žene, i to Hrvatsku stavlja kao treću najslabiju zemlju po stopi zaposlenosti žena. Jedino Grčka i Italija imaju nižu stopu zaposlenosti žena od Hrvatske, dok su susjedne zemlje Slovenija i Mađarska za 11, odnosno 7 postotnih bodova iznad stope u Hrvatskoj. Europska komisija (2015) u svom izvještaju o starenju navodi kako je Hrvatska jedna od država članica za koju se na temelju demografskih projekcija predviđa veće smanjenje broja radno sposobne populacije. Stoga, Hrvatska kao zemlja s vrlo niskom stopom zaposlenosti žena i sa problemom starenja stanovništva, ima veliki potencijal za povećanje ponude radne snage kroz uključivanje sve većeg broja žena u radnu snagu (Europska komisija, 2017a). Iako u Hrvatskoj muškarci imaju znatno višu stopu zaposlenosti od žena, ista je također niža od prosjeka EU-a i to za oko 8 postotnih bodova. Nadalje, sa stopom zaposlenosti muškaraca od oko 69% Hrvatska je ispred Grčke na pretposljednjem mjestu, a susjedne zemlje poput Mađarske i Slovenije su po ovom pokazatelju ispred Hrvatske za dosta velikih 12, odnosno 8 postotnih bodova.



Slika 2.2. Stopa zaposlenosti u 2017. za populaciju od 20 do 64 godine prema spolu, %
Izvor: Eurostat, anketa o radnoj snazi (lfsa_ergan)

Što se tiče razine obrazovanja, slika 2.3. pokazuje kako su osobe s niskim obrazovanjem posebno „rizična“ skupina s obzirom na stopu zaposlenosti. U Hrvatskoj je 2017. bilo

zaposleno tek oko trećine radno sposobne populacije u dobi od 20 do 64 godine s osnovnim stupnjem obrazovanja, što je za oko 20 postotnih bodova manje od prosjeka EU-a koji iznosi oko 55%, a ujedno je i Hrvatska zadnja zemlja unutar EU-a po spomenutom pokazatelju. Susjedne zemlje, Mađarska i Slovenija, ne zaostaju puno za prosjekom EU-a, točnije Mađarska zaostaje za 1 postotni bod, dok Slovenija zaostaje za oko 5 postotnih bodova. S povećanjem stupnja obrazovanja stanje u Hrvatskoj se poboljšava, odnosno Hrvatska manje zaostaje za prosjekom EU-a. Tako stopa zaposlenosti populacije sa srednjim stupnjem kao najvišim stupnjem obrazovanja iznosi oko 64%, što je za oko 8 postotnih bodova niže od prosjeka EU-a. U toj skupini Hrvatska više nije posljednja po stopi zaposlenosti, no ipak samo su Grčka i Španjolska lošije od Hrvatske. Konačno, uspoređujući s prosjekom EU-a, stanje u Hrvatskoj se još više poboljšava ako se promatra populacija s višim/visokim stupnjem obrazovanja. Zaposleno je 81,5% radno sposobne populacije s višim/visokim stupnjem obrazovanja, što je tek za 2,5 postotnih bodova manje od prosjeka EU-a, a taj rezultat Hrvatsku stavlja kao zemlju s šestom najnižim stopom zaposlenosti unutar EU-a za tu podskupinu. Stopa zaposlenosti u Mađarskoj za spomenutu podskupinu iznosi oko 84%, što je jednako prosjeku EU-a, dok je u Sloveniji ta stopa viša za oko 2 postotna boda od prosjeka EU-a.



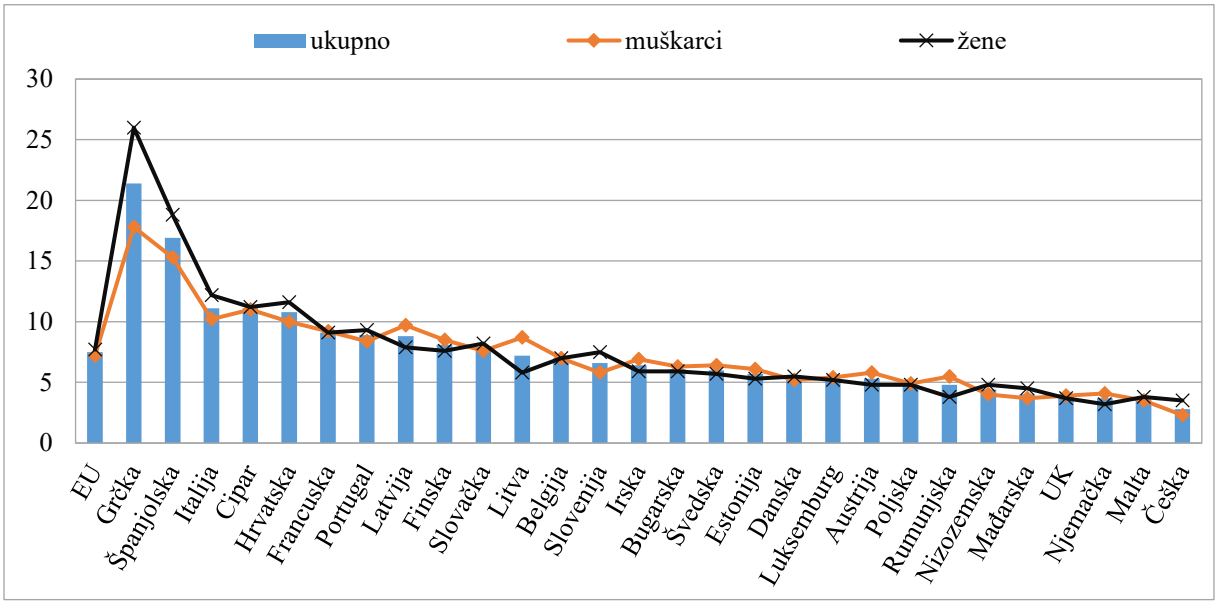
Slika 2.3. Stopa zaposlenosti u 2017. za populaciju od 20 do 64 godine prema stupnju obrazovanja, %
Izvor: Eurostat, anketa o radnoj snazi (lfsa_ergaed)

Nezaposlena populacija

Stanje nezaposlenosti ima negativan utjecaj na pojedinca i društvo. Glavna karakteristika nezaposlenih osoba na tržištu rada je da su one uključene u aktivno traženje posla, no pojedine

osobe ne uspijevaju naći posao niti u periodu od jedne godine. Takve osobe, koje traže posao više od 12 mjeseci, smatraju se dugotrajno nezaposlenim osobama i kao takve one su ozbiljno izložene ekonomskom siromaštvu i socijalnoj izdvojenosti (Bejaković, 2003). Također, isti autor navodi kako se rad smatra „najboljim oblikom socijalne skrbi" te bi glavni ciljevi politike tržišta rada i socijalne politike trebali biti smanjenje stope (dugotrajne) nezaposlenosti, odnosno povećanje stope zaposlenosti. Nezaposlenost, a posebice dugotrajna, osobito loše utječu na mlađe osobe, odnosno na osobe s malo ili bez radnog iskustva. Nezaposlenost na početku karijere može stvoriti dugoročne negativne posljedice, kao što su nemogućnost ostvarivanja višeg dohotka u budućnosti i stvaranje lošijih izgleda za zapošljavanje (Europska komisija, 2017b). Dodatno, Bejaković (2018) navodi kako dugotrajna nezaposlenost može imati i ozbiljnije posljedice od samog smanjenja dohotka, a to su zastarijevanje znanja i stručnosti te razne druge štete.

Za prikaz stvarnog stanja nezaposlenosti u Hrvatskoj koristi se stopa nezaposlenosti koja je pokazatelj koji mjeri udio nezaposlene populacije u radno aktivnoj populaciji. Prema rezultatima iz 2017. Hrvatska je na petom mjestu unutar EU-a prema visini stope nezaposlenosti populacije u dobi od 20 do 64 godine (slika 2.4.). Točnije, oko 11% radno aktivne populacije u toj dobi je nezaposleno što je za oko 3 postotna boda više od prosjeka EU-a.

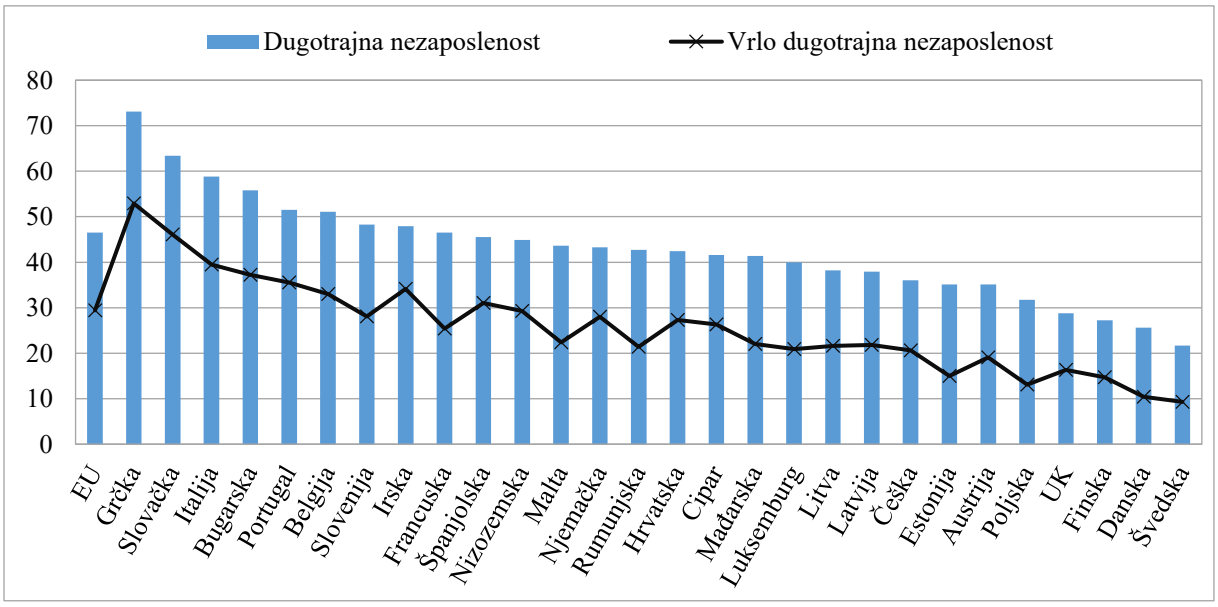


Slika 2.4. Stopa nezaposlenosti u 2017. za populaciju od 20 do 64 godine prema spolu, %
Izvor: Eurostat, anketa o radnoj snazi (lfsa_urgan)

Od susjednih zemalja, Mađarska, Austrija i Slovenija su bolje rangirane od Hrvatske, odnosno imaju niže stope nezaposlenosti koje redom iznose 4,0%, 5,3% i 6,6%, dok je u Italiji stopa nezaposlenosti viša za oko 0,3 postotna boda nego u Hrvatskoj. Što se tiče jaza u stopi

nezaposlenosti između spolova, stopa nezaposlenosti žena u Hrvatskoj je za 1,6 postotna boda viša od stope nezaposlenosti muškaraca. U usporedbi sa stopom nezaposlenosti muškaraca, u spomenutim susjednim zemljama je stopa nezaposlenosti žena veća u Italiji, Sloveniji i Mađarskoj i to redom za 2,0, 1,7 i 0,8 postotnih bodova. S druge strane, u Austriji je stopa nezaposlenosti muškaraca veća za 1 postotni bod od stope nezaposlenosti žena.

Nadalje, slika 2.5. prikazuje kako je u Hrvatskoj oko 42% nezaposlene populacije dugotrajno nezaposleno, što je za oko 5 postotnih bodova manje od prosjeka EU-a. Po ovom pokazatelju Hrvatska je slična zemljama poput Njemačke, Malte, Rumunjske, Cipra i Mađarske, a zemlje s najmanjim udjelom dugotrajno nezaposlenih su Danska i Švedska, čiji udjeli redom iznose oko 26% i 23%. Slika 2.5. prikazuje i udio vrlo dugotrajno nezaposlenih osoba u ukupno nezaposlenima, a to su osobe koje su nezaposlene više od dvije godine. Tako je u Hrvatskoj 2017. više od četvrtine nezaposlenih osoba (27,3%) bilo vrlo dugotrajno nezaposleno, što je za 2 postotna boda niže od prosjeka EU-a.

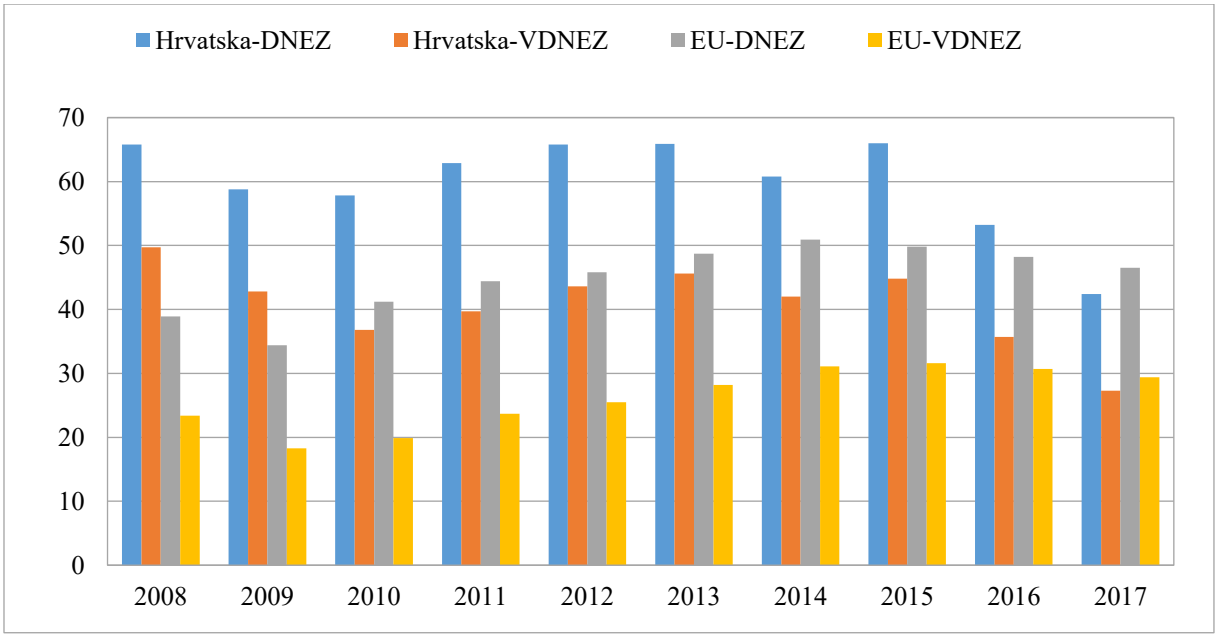


Slika 2.5. Udio dugotrajne i vrlo dugotrajne nezaposlenosti u ukupnoj nezaposlenosti u 2017. za populaciju od 20 do 64 godine, %
Izvor: Eurostat, anketa o radnoj snazi (une_ltu_a)

Što se tiče kretanja udjela dugotrajne nezaposlenosti u ukupnoj stopi nezaposlenosti kroz godine, slika 2.6. ilustrira kako je udio dugotrajno nezaposlenih osoba u dobi od 20 do 64 godine u Hrvatskoj pao ispod 50% tek u 2017. i tada je taj udio pao ispod prosjeka EU-a. Naime, u 2008. oko dvije trećine nezaposlenih osoba je bilo dugotrajno nezaposleno što je tada bilo za oko 27 postotnih bodova više od prosjeka EU-a. Nakon 2008., udio dugotrajno nezaposlenih u Hrvatskoj se smanjuje za oko 8 postotnih bodova, no od 2012. do 2015.

ponovno je oko dvije trećine nezaposlenih dugotrajno nezaposleno, iznimka je 2014. kada je taj udio nešto manji i iznosio je oko 61%. Nakon 2015., u kojoj je udio dugotrajno nezaposlenih osoba u Hrvatskoj za oko 16 postotnih bodova veći od prosjeka EU-a, udio dugotrajno nezaposlenih osoba u Hrvatskoj počinje padati brže od prosjeka EU-a, da bi u 2017. taj udio dugotrajno nezaposlenih pao ispod prosjeka EU-a.

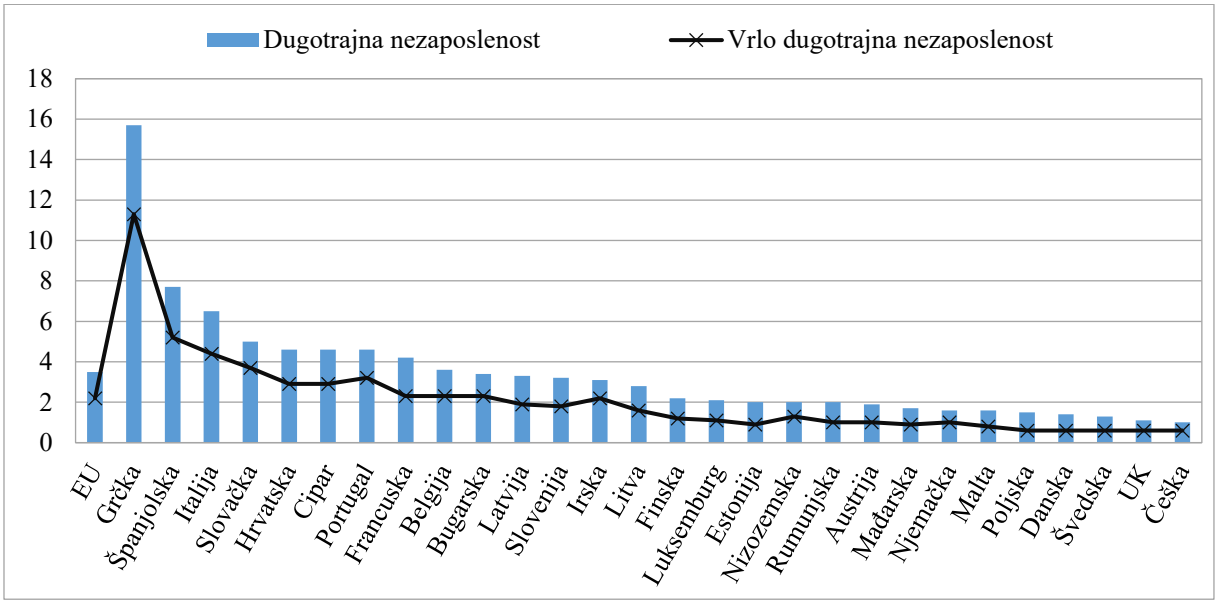
Nadalje, u vremenskom razdoblju od 2008. do 2017. udio vrlo dugotrajne nezaposlenosti u ukupnoj nezaposlenosti osoba u dobi od 20 do 64 godine u Hrvatskoj bio je najviši u 2008.,kada je polovica nezaposlenih osoba bilo nezaposleno dulje od dvije godine, a to je tada bilo za oko 26 postotnih bodova iznad prosjeka EU-a. Udio vrlo dugotrajne nezaposlenosti padao je do 2010. kada je iznosio oko 37%, nakon čega taj udio opet raste sve do 2015. kada je oko 45% nezaposlenih osoba bilo dugotrajno nezaposleno, što je za oko 13 postotnih bodova veće od prosjeka EU-a u 2015. U naredne dvije godine udio vrlo dugotrajne nezaposlenosti ponovno pada, te se u 2017. izjednačava s prosjekom EU-a, a čak je i niži za 2 postotna boda.



Slika 2.6. Kretanje udjela dugotrajne i vrlo dugotrajne stope nezaposlenosti u ukupnoj stopi nezaposlenosti u Hrvatskoj kroz godine za populaciju od 20 do 64 godine, %
Izvor: Eurostat, anketa o radnoj snazi (une_ltu_a)
Kratice: DNEZ – dugotrajna nezaposlenost; VDNEZ – vrlo dugotrajna nezaposlenost

Na temelju prethodne dvije slike analizirali su se udjeli dugotrajne i vrlo dugotrajne nezaposlenosti u ukupnoj nezaposlenosti, no one ne daju podatak koliko ustvari ima takvih osoba. Kako bi se to odredilo, analizira se slika 2.7. koja prikazuje stope dugotrajne ili vrlo dugotrajne nezaposlenosti koje se definiraju kao udio dugotrajno ili vrlo dugotrajno nezaposlene populacije

u ukupno aktivnoj populaciji. Hrvatska je u 2017. imala stope dugotrajne i vrlo dugotrajne nezaposlenosti od 4,6% i 2,9%, što je za 1,1, odnosno 0,7 postotnih bodova više od prosjeka EU-a. Zemlja s najvišom stopom dugotrajne i vrlo dugotrajne nezaposlenosti je Grčka, dok je Češka zemlja s najnižom stopom. Susjedna zemlja Slovenija je prema visini dugotrajne i vrlo dugotrajne stope nezaposlenosti bila na razini prosjeka EU-a, odnosno u Sloveniji su te stope bile za oko 0,3 postotna boda niže od prosjeka EU-a.



Slika 2.7. Stopa dugotrajne i vrlo dugotrajne nezaposlenosti u 2017. za populaciju od 20 do 64 godine, %
Izvor: Eurostat, anketa o radnoj snazi (une_ltu_a)

Neaktivna populacija

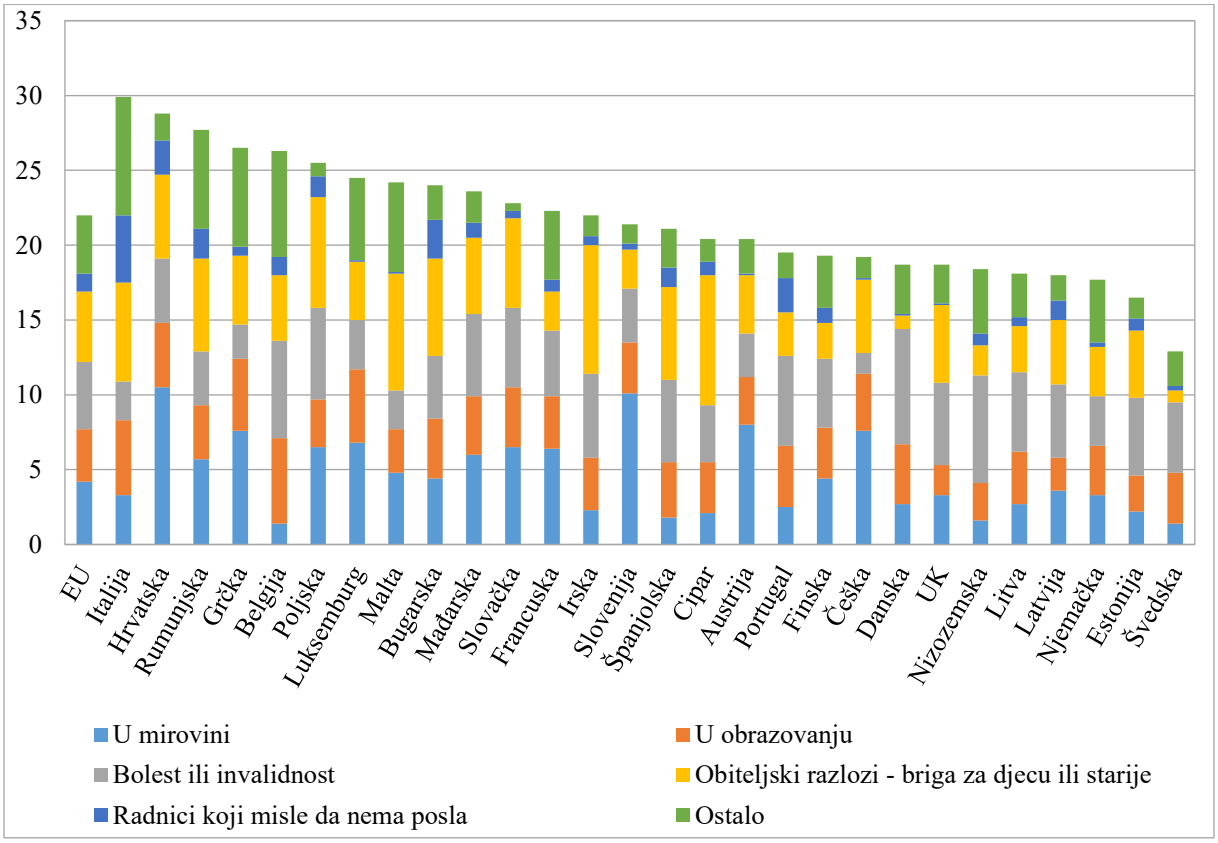
U neaktivnu populaciju uključene su različite heterogene skupine spomenute u poglavlju 2.1., a glavna karakteristika im je da nisu uključene u aktivno traženje posla. Hrvatska je 2017. nakon Italije bila druga zemlja EU-a po visini stope neaktivnosti za populaciju u dobi od 20 do 64 godine. Sa stopom neaktivnosti od 29% Hrvatska je stajala 7 postotnih bodova iznad prosjeka EU-a. S druge strane, sa stopom neaktivnosti od 13% Švedska je bila na dnu ove ljestvice.

Slika 2.8. prikazuje kako su glavni razlozi za neaktivnost na razini EU-a za populaciju u dobi od 20 do 64 godine u 2017. bili obiteljski razlozi - briga za djecu i starije (4,7%), nesposobnost za rad (4,5%), umirovljenje (4,2%), obrazovanje (3,5%), uvjerenje osobe kako nema adekvatnog posla za nju (1,2%), te ostali razlozi (3,9%). Najvažniji razlog za neaktivnost u Hrvatskoj bilo je umirovljenje, jer je 10,5% populacije u dobi od 20 do 64 godine bilo umirovljeno, što je za 6,3 postotna boda više od prosjeka EU-a. Odmah iza Hrvatske nalaze se Slovenija i Austrija gdje je 10,1%, odnosno 8,0% populacije od 20 do 64 bilo u mirovini,

a to su ujedno bili glavni razlozi za neaktivnost u tim zemljama. Zemlje s najmanjim udjelom umirovljenika u populaciji (20-64) bile su Belgija i Švedska, obje s udjelom od 1,4%.

Nesposobnost za rad kao razlog ostanka izvan tržišta rada najviše se ističe u nekim zemljama zapadne Europe, kao što su Danska, Nizozemska i Belgija, gdje je redom 7,7%, 7,5% i 6,5% populacije u dobi 20 do 64 godine radno nesposobno. Udio radno nesposobnih u Hrvatskoj je 4,3%, što je jednako prosjeku EU-a. Nadalje, u Hrvatskoj se 4,3% populacije (20-64) nalazi u sustavu obrazovanja, a udio populacije u dobi 20 do 64 godine koji se nalazi u sustavu obrazovanja kreće se od najnižih 2,0%, koliko iznosi u UK, do maksimuma od 5,7% u Belgiji.

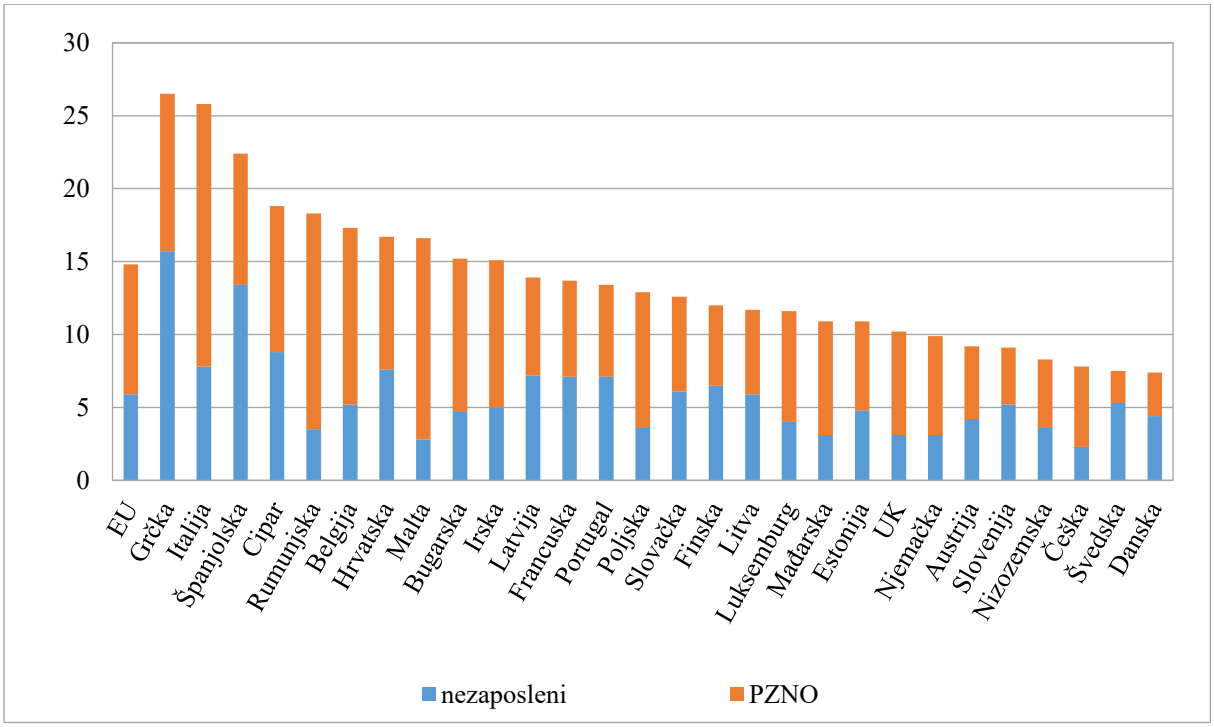
U Cipru i Irskoj je najveći udio populacije u dobi od 20 do 64 godine kao razlog izostanka iz tržišta rada naveo obiteljske razloge (briga za djecu ili starije), i to redom 8,7% i 8,6% njih, dok je najmanji udio u Švedskoj, gdje iznosi 0,8%. Što se tiče Hrvatske, 5,6% populacije u dobi 20 do 64 kao razlog neaktivnosti navelo je obiteljske razloge, što je za 0,9 postotna boda veće od prosjeka EU-a. Mišljenje kako nema adekvatnog posla kao razlog neaktivnosti najviše se ističe u Italiji (4,5%), Bugarskoj (2,6%), Portugalu (2,3%) i Hrvatskoj (2,3%), a najmanje u zemljama poput Austrije, Češke, Danske, Malte, Luksemburga i UK-a.



Slika 2.8. Struktura neaktivne populacije u 2017. za populaciju od 20 do 64 godine, %
Izvor: Eurostat, anketa o radnoj snazi (lfsa_igar)

2.1.2. Potencijalno zapošljive osobe koje se nalaze izvan rada i potencijalna radna snaga

Kako je već definirano u poglavlju 2.1., spajanjem populacije potencijalno zapošljivih neaktivnih osoba (PZNO) s populacijom nezaposlenih osoba dobiva se skup potencijalno zapošljivih osoba izvan rada (PZOIR). Slika 2.9. prikazuje kako je u 2017. najveći udio PZOIR populacije (20-64) bio u Grčkoj (26,5%), Italiji (25,8%) i Španjolskoj (22,4%). Zemlje s najmanjim udjelom PZOIR populacije su Danska (7,4%) i Švedska (7,5%), što je za oko 7 postotnih bodova niže od prosjeka EU-a, koji iznosi 14,8%. Hrvatska ima sedmi najviši udio PZOIR populacije, od 16,7%, što je za oko 2 postotna boda iznad prosjeka EU-a. Susjedne zemlje poput Slovenije i Mađarske imaju niže udjele PZOIR populacije od Hrvatske i to redom za 7,6 i 5,8 postotnih bodova.

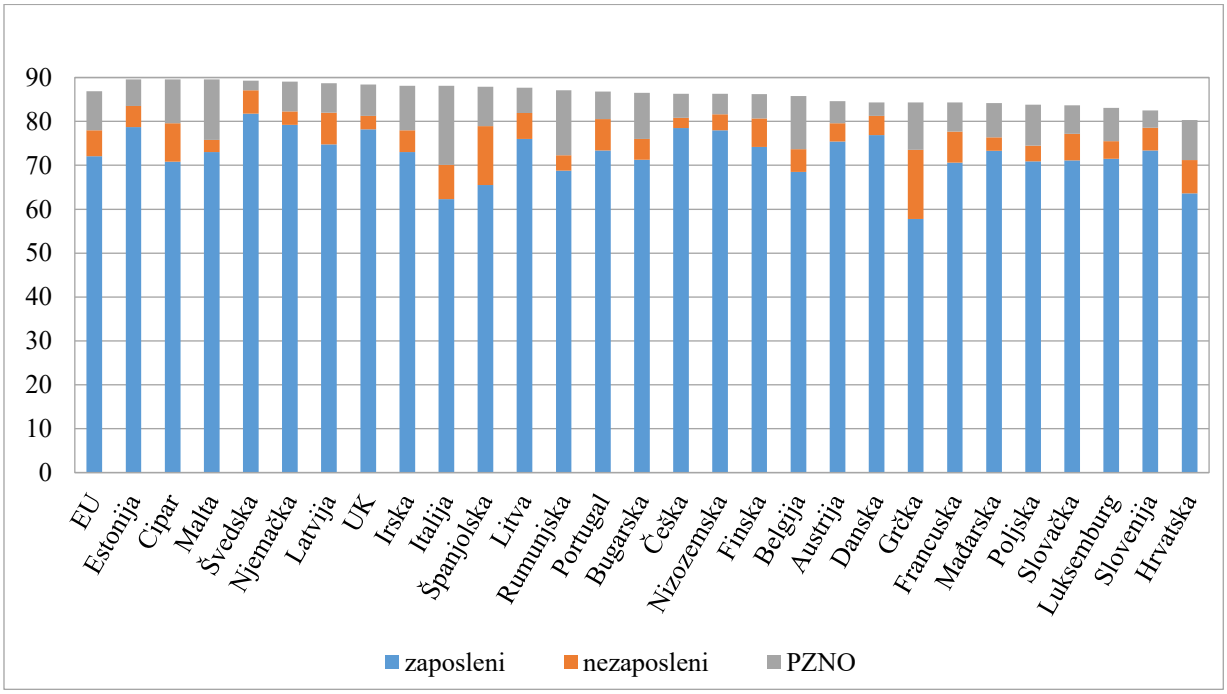


Slika 2.9. Udio nezaposlenih i potencijalno zapošljivih neaktivnih osoba u 2017. za populaciju od 20 do 64 godine u Hrvatskoj, %

Izvor: Eurostat, autorovi izračuni na temelju ankete o radnoj snazi (lfsa_argan, lfsa_ergan, lfsa_igar)

U smislu postizanja planova oko željene stope zaposlenosti u budućnosti zanimljivo je vidjeti koliko u pojedinim zemljama zapravo ima potencijalne radne snage. Stope aktivnosti govore koliko ima radno aktivne populacije koju čine zaposlene i nezaposlene osobe. Međutim, kako i u neaktivnoj populaciji postoje osobe koje su uz određene uvjete voljne prihvatiti posao, zbroj zaposlenih, nezaposlenih i PZNO osoba se po uzoru na rad Nestić i Tomić (2018) može definirati kao *potencijalna radna snaga*. Stoga, kako bi se vidjelo koliko pojedina zemlja ima potencijalne radne snage u dobi od 20 do 64 godine, slika 2.10. istovremeno prikazuje udjele

zaposlenih, nezaposlenih i PZNO osoba u ukupnoj populaciji 20-64. Rezultati pokazuju kako je Hrvatska na posljednjem mjestu, s najmanjim udjelom potencijalne radne snage u ukupnoj populaciji (20-64), koji iznosi oko 80%, što je 7 postotnih bodova niže od prosjeka EU-a. Iako Hrvatska zajedno s Italijom, Španjolskom i Grčkom ima najniže stope zaposlenosti, te zemlje imaju ipak veći prostor za povećanje radne snage nego ostale zemlje, budući da im je udio PZOIR populacije među najvišim unutar EU-a. Nadalje, Slovenija je zemlja s vrlo visokom stopom zaposlenosti u 2017., od oko 73%, što je za oko 1 postotni bod više od prosjeka EU-a, a oko 10 postotnih bodova više od Hrvatske. Međutim, Slovenija je s oko 82% potencijalne radne snage odmah iza Hrvatske na pretposljednjem mjestu. Jedan od razloga je da Slovenija kao i Hrvatska imaju najveći udio umirovljenika u populaciji (20-64) koji iznosi oko 10%, a udio PZOIR populacije joj iznosi oko 9%.

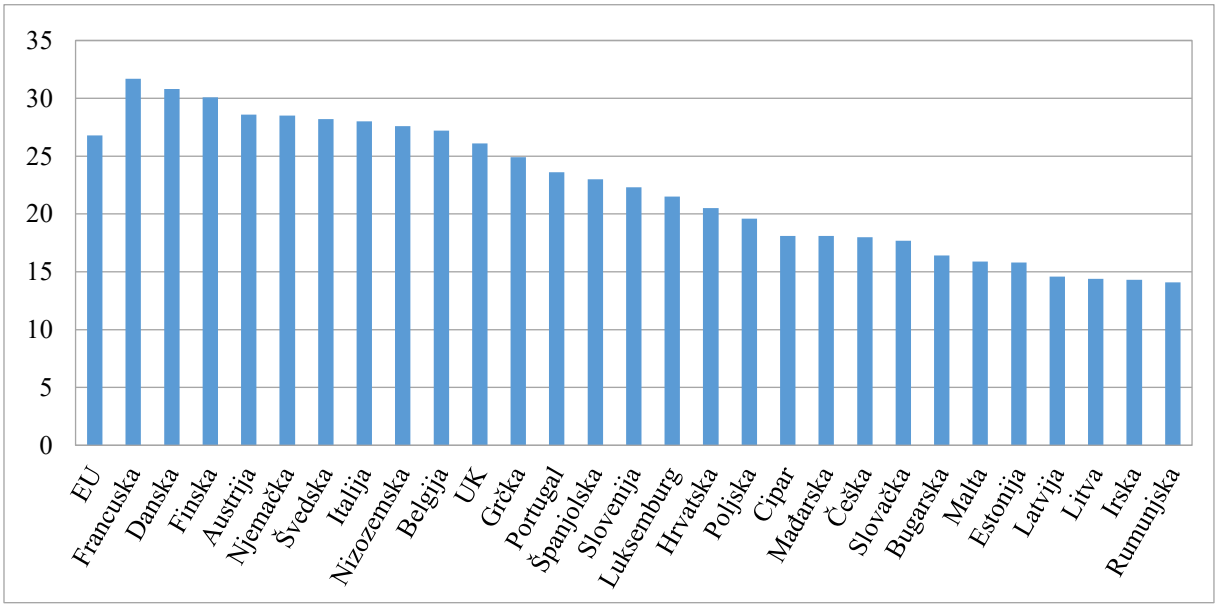


Slika 2.10. Potencijalna radna snaga u 2017. za populaciju od 20 do 64 godine, %
Izvor: Eurostat, autorovi izračuni na temelju ankete o radnoj snazi (lfsa_argan, lfsa_ergan, lfsa_igar)

Dakle, rezultati iz prethodne slike pokazuju kako u pojedinim zemljama postoji ograničen potencijal u dostizanju planova Europske komisije (2010), koja je na temelju plana *Europe 2020* za cilj postavila dostizanje stope zaposlenosti populacije (20-64) od najmanje 75% do 2020. Uzimajući samo aktivnu populaciju (20-64) u Hrvatskoj, koje u 2017. ima 71,2%, Hrvatska bi zbog nedostatka radne snage bila limitirana u postizanju zadanog cilja. Stoga bi u smislu dostizanja stope zaposlenosti od 75%, Hrvatska trebala potaknuti i PZNO populaciju za prijeđe u stanje zaposlenosti.

2.1.3. Socijalni transferi i siromaštvo

Siromaštvo se obično definira kao nemogućnost zadovoljenja osnovnih materijalnih potreba, osobito adekvatne prehrane, ali i osiguravanja zadovoljavajućeg mjesta za stanovanje i druge imovine (Bejaković, 2005). Bejaković (2017) navodi kako siromaštvo u Hrvatskoj stagnira, te da je onima koji postanu siromašni potrebno dugo razdoblje za bijeg od siromaštva. Isto tako ističe kako su neaktivne i nezaposlene osobe najčešće skupine siromašnih u Hrvatskoj. Postoje različite mjere kojima se može ublažiti siromaštvo, a za postizanje tog cilja potrebno je fokusirati se na poboljšanje stupnja obrazovanja, povećanje zaposlenosti, te općenito raditi na poboljšanju stanja na tržištu rada. Također je potrebno stvarati uključiva tržišta rada, koja omogućuju svima steći pravo na plaćeno zaposlenje i imati priliku zaraditi plaću koja će biti dovoljna za dostojanstven život (Europska komisija, 2017c). Stvaranje uključivih tržišta rada posebno se oslanja na aktivne politike tržišta rada čiji je cilj nezaposlenim osobama pružati potporu u što bržem pronalaženju posla, koji najbolje odgovara njihovim kvalifikacijama (Europska komisija, 2017d). S druge strane, onima koji ostanu izvan tržišta rada ili koji mogu zaraditi samo niske plaće, potrebno je osigurati potpore dohotku, ali kod radno sposobnih osoba potrebno je voditi računa da se izbjegnu zamke, odnosno stupice neaktivnosti ili nezaposlenosti (Europska komisija, 2017c).[3]



Slika 2.11. Ukupni izdatci za programe socijalne zaštite u 2017., % BDP-a
Izvor: Eurostat, ESSPROS (spr_exp_sum)

[3] Carone i sur (2009) definiraju stupicu nezaposlenosti kao situaciju u kojoj su naknade za nezaposlene osobe relativno visoke u odnosu na neto dohodak od rada i kada se pravo na naknadu ostvaruje kroz dulje razdoblje. Stupica neaktivnosti je slična situacija kao i stupica nezaposlenosti, samo što se ona ne primjenjuje na osobe koje primaju naknadu za nezaposlenost, nego se primjenjuje na osobe koje primaju relativno visoke pomoći iz sustava socijalne skrbi koje se dodjeljuju na temelju dohodovnog cenzusa.

Bejaković (2013) spominje kako su rashodi unutar velikih socijalnih programa (npr. rashodi za mirovine) manje orijentirani na siromašne osobe, dok su programi socijalnih pomoći koji troše manje financijskih sredstava snažnije usmjereni na siromašniju populaciju. Podaci za 2017. (slika 2.11.) pokazuju kako Hrvatska troši 20,5% BDP-a na programe socijalne zaštite što je za oko 6 postotnih bodova manje od prosjeka EU-a. U usporedbi s drugim zemljama EU-a, Hrvatska je prema analiziranom pokazatelju najsličnija zemljama poput Slovenije (22,3%), Luksemburga (21,5%) i Poljske (19,6%). Francuska je zemlja koja izdvaja najveći udio BDP-a na programe socijalne zaštite (32,7%), dok Rumunjska izdvaja najmanji udio BDP-a (14,1%).

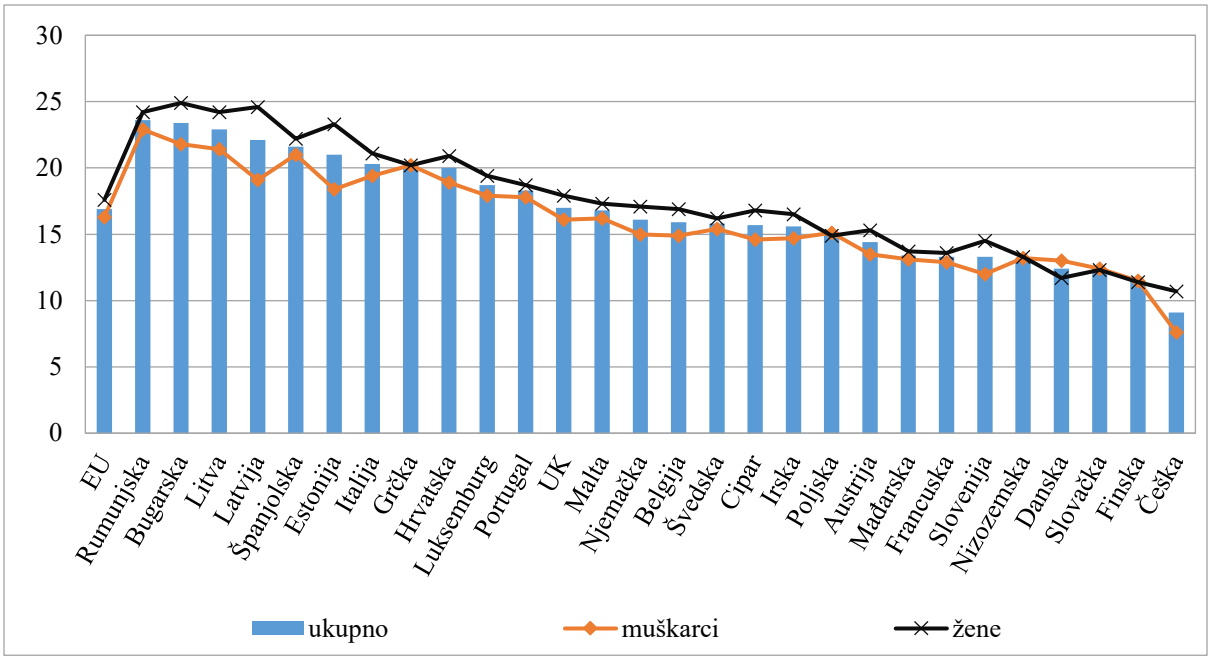
Tablica 2.1. pokazuje da najveći izdaci u Hrvatskoj u 2017. unutar programa socijalne zaštite otpadaju na starosne mirovine, 7,1% BDP-a, što je za oko 3,7 postotnih bodova manje od prosjeka EU-a. Druga najveća stavka su izdatci za bolovanje i zdravstvenu skrb, koji u Hrvatskoj iznose 6,9% BDP-a, a prosjek EU-a je 7,9%. Nadalje, na programe socijalne pomoći namijenjene obitelji i djeci i na naknade za stanovanje i ostale naknade za socijalnu isključenost u Hrvatskoj se trošilo 2,1% BDP-a, što je za 0,3 postotna boda niže od prosjeka EU-a. Na naknade za nezaposlene se u Hrvatskoj trošilo 0,4% BDP-a, dok je prosjek EU-a tri puta veći.

Tablica 2.1. Komponente izdataka u sustavu socijalne zaštite u 2017, u % BPD-a

	Hrvatska	EU-28
Ukupni izdaci za naknade socijalne zaštite	20,5	26,8
Bolest/zdravstvena skrb	6,9	7,9
Invaliditet	2,2	2,0
Starosne mirovine	7,1	10,8
Preživjeli uzdržavani članovi	1,8	1,4
Nezaposlenost	0,4	1,2
Obitelj/djeca	1,8	2,3
Stanovanje i socijalna isključenost koja nije drugdje klasificirana	0,3	1,1

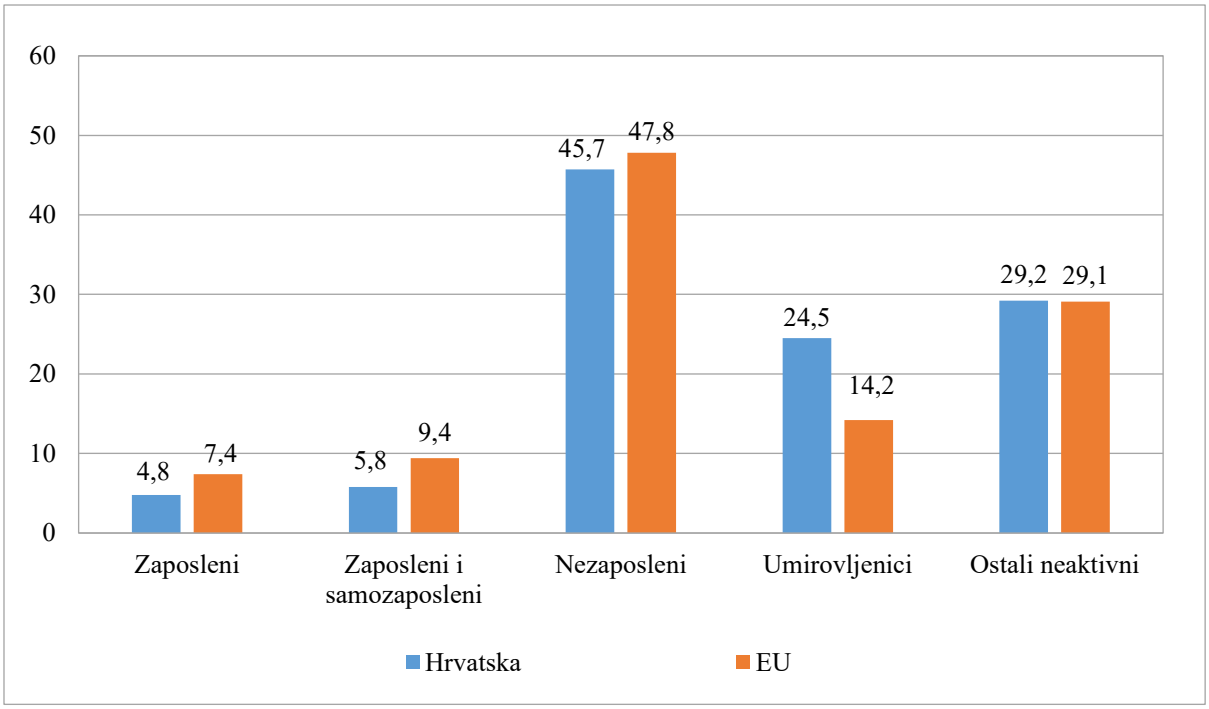
Izvor: Eurostat, ESSPROS (spr_exp_sum)

Stopa rizika od siromaštva u Hrvatskoj u 2017. iznosila je 20,0%, što je za oko 3 postotna boda više od prosjeka EU-a, a prema visini stope Hrvatska je na devetom mjestu u EU-u (slika 2.12.). Najniža stopa rizika od siromaštva zabilježena je u Češkoj (9,1%), dok su najviše stope zabilježene u Litvi (22,9%), Bugarskoj (23,4%) i Rumunjskoj (23,6%). Najveći jaz između spolova bio je u Latviji i Estoniji, gdje su žene imale za oko 5 postotnih bodova veću stopu rizika od siromaštva od muškaraca. U Hrvatskoj žene također imaju veću stopu rizika od siromaštva nego muškarci, a razlika iznosi 2,0 postotna boda, što je blizu prosjeka EU-a, gdje jaz između spolova iznosi 1,3 postotna boda.



Slika 2.12. Stopa rizika od siromaštva u 2017. prema spolu, %
Izvor: Eurostat, EU-SILC anketa (ilc_li02)

Analizom stope rizika od siromaštva prema najčešćem statusu aktivnosti pokazalo se kako su nezaposlene osobe skupina s najvećom stopom rizika od siromaštva u Hrvatskoj, koja iznosi oko 46% (slika 2.13.). Stopu rizika od siromaštva višu od prosjeka za cjelokupnu populaciju u Hrvatskoj također imaju i preostale dvije promatrane skupine osoba izvan rada, umirovljenici (24,5%) i ostale neaktivne osobe (29,2%). Nadalje, u Hrvatskoj je stopa rizika od siromaštva nezaposlenih osoba za oko 2 postotna boda viša od prosjeka EU-a, stopa rizika od siromaštva za ostale neaktivne je jednaka prosjeku EU-a, dok je stopa rizika od siromaštva umirovljenika u Hrvatskoj viša za čak 10 postotnih bodova od prosjeka EU-a. S druge strane, zaposlene i samozaposlene osobe u Hrvatskoj imaju relativno nisku stopu rizika od siromaštva koja iznosi 5,8% (3,6 postotnih bodova niže od prosjeka EU-a), dok je za zaposlene osobe koje rade kod poslodavca stopa rizika još niža, i iznosi 4,8% (2,6 postotnih bodova niže od prosjeka EU-a).



Slika 2.13. Stopa rizika od siromaštva u 2017. prema najčešćem statusu aktivnosti, %
Izvor: Eurostat, EU-SILC anketa (ilc_li04)

2.2. Isplativost rada: koncept i mjerenje

Glavna namjena socijalnih naknada je osigurati prihvatljiv životni standard za kućanstva koja nisu u mogućnosti ostvariti dohodak iz drugih izvora. Budući da djeluju kao mjere protiv siromaštva, socijalne naknade smanjuju razlike u dohotku na dnu dohodovnog spektra te predstavljaju važnu ulogu u politici preraspodjele (Immervoll, 2009.). Jednako tako, socijalne naknade pružaju određenu materijalnu sigurnost osobama s niskim primanjima i pomažu im u izglađivanju razine dohotka tijekom vremena.

Međutim, visoki iznosi naknada koje primaju osobe izvan rada mogu rad učiniti manje privlačnim i tako utjecati na smanjenje poticaja za prihvaćanje zaposlenja, što je posebno izraženo u slučaju kada se osoba može zaposliti samo na niskim razinama bruto plaće. Za takve osobe iznos socijalnih naknada u stanju kada ne rade gotovo je jednak neto dohotku kojeg bi te osobe mogle ostvariti kada bi se zaposlile. Spomenute osobe nemaju gotovo nikakve financijske poticaje za prihvaćanje zaposlenja te upadaju u zamku nezaposlenosti ili neaktivnosti. Dodatno, u situaciji velikodušnih iznosa socijalnih naknada, osobe koje trenutno rade uz niske iznose bruto plaća nemaju financijski motiv za ostankom u zaposlenosti pa posljedično takve osobe ulažu manje napora u očuvanje posla.

Od socijalnih naknada koje utječu na isplativost rada u literaturi se spominju naknada za nezaposlene, socijalna pomoć i pomoć za troškove stanovanja te naknade za djecu. Što je veći iznos naknade za nezaposlene i što je dulje razdoblje njihova primanja, manja je razlika između dohotka koji se ostvaruje u stanju nezaposlenosti i dohotka koje bi se ostvarivao u slučaju zaposlenja. Na taj način smanjuju se poticaji nezaposlenih osoba za prihvaćanje posla, osobito slabije plaćenih, jer se iznos naknade u potpunosti gubi prilikom zaposlenja. Carone i sur. (2009) spominju kako, s druge strane, naknada za nezaposlene omogućuje nezaposlenim osobama više vremena za pronalaženje odgovarajućeg posla koji će odgovarati njihovim radnim vještinama i tako povećati njihovu produktivnost na novom poslu.

Kućanstva s nižim primanjima koja nemaju pravo na naknadu za nezaposlene ili im je isteklo vremensko razdoblje primanja naknade mogu steći pravo na socijalnu pomoć i pomoć za troškove stanovanja koje se dobivaju prema dohodovnom cenzusu. Primarni cilj takvih naknada je reducirati siromaštvo djece, ali i ukupne populacije, no one također mogu izazvati negativne poticaje za rad, osobito samohranih roditelja ili kućanstava u kojima niti jedan odrasli član ne radi, jer bi prilikom zaposlenja prestalo pravo na primanje socijalnih naknada (Carone i sur., 2009). Naknade za djecu koje se dodjeljuju prema dohodovnom cenzusu kućanstva također smanjuju poticaje za rad. Međutim, u nekim zemljama postoje univerzalne naknade za djecu koje se dodjeljuju neovisno o dohodovnom cenzusu pa takav tip naknade ne djeluje negativno na isplativost rada.

Ukupni iznos isplaćenih naknada određuje i visinu javnih izdataka za financiranje sustava socijalnih naknada. Spomenuti teret financiranja zajedno snose poslodavci i zaposlenici što posljedično dovodi do činjenice da velikodušni sustavi socijalnih naknada povećavaju troškove rada i time mogu utjecati na smanjenje zaposlenosti (Carey i Tchilinguirian, 2000; Immervoll i O'Donoghue, 2002a). Također, izdašni iznosi socijalnih naknada povećavaju pregovaračku moć zaposlenika i tako povećavaju potencijalni iznos nadnica (Layard i sur., 1991).

Uz socijalne naknade, porezno opterećenje rada također utječe na financijske poticaje za rad na strani ponude i potražnje. Porezno opterećenje rada stvara klin između ukupnih troškova rada koje plaća poslodavac i realne neto plaće koju prima zaposlenik. Na strani potražnje visoki iznosi poreznog tereta utječu na ukupne troškove rada, a na strani ponude visoki porezni teret utječe na smanjenje poticaja za povećanje radnih sati zaposlenih osoba (Immervoll i O'Donoghue, 2002b) ili na smanjenje poticaja za prihvaćanje posla s plaćama na donjem kraju ljestvice plaća (Carone i sur., 2009). Tako su Daveri i Tabellini (2000) i

Vodopivec (2004) dokazali statistički značajnu pozitivnu povezanost poreznog klina i stope nezaposlenosti, te negativnu povezanost poreznog klina s ponudom rada i stopom zaposlenosti. Navedenu činjenicu je potvrdilo i istraživanje koje su proveli Dolenc i Laporšek (2010) za zemlje EU-27. Spomenuti autori su na temelju empirijske analize pokazali da smanjenje poreznog klina povećava stopu zaposlenosti i rast zaposlenosti te smanjuje nezaposlenost, što je posebno izraženo za zemlje s najvećim poreznim klinom. Lehmann i sur. (2016) su na uzorku od 21 zemlje OECD-a potvrdili rezultate prethodno spomenutog istraživanja (Dolenc i Laporšek, 2010) i dodatno su pokazali kako su progresivniji porezni rasporedi povezani s nižim stopama nezaposlenosti i višim stopama zaposlenosti.

Što se tiče istraživanja za Hrvatsku, Šeparović (2009) je pokazala statistički značajnu povezanost između visine poreznog klina i stope nezaposlenosti te zaključila da je Hrvatska zemlja s visokim poreznim klinom i visokom stopom nezaposlenosti. Nadalje, Dolenc i sur. (2011) su na temelju regresijske analize pokazali statistički značajnu pozitivnu povezanost između visine poreznog klina i stope nezaposlenosti, a Deskar-Škrbić i sur. (2018) su također pokazali da visina poreznog klina ima statistički značajnu negativnu povezanost sa stopom zaposlenosti. Iste rezultate dobili su Dolenc i Vodopivec (2005a) koji su pokazali da i u Sloveniji postoji značajna povezanost između visine poreznog klina i stope nezaposlenosti te negativna povezanost poreznog klina i stope zaposlenosti.

Dakle, ponuda radne snage uvjetovana je cjelokupnim dizajnom sustava poreza i socijalnih naknada (visinom poreznog klina i izdašnošću socijalnog sustava), koji pak određuje financijske poticaje za ulazak u svijet rada nezaposlenih ili neaktivnih osoba. Spomenuti financijski poticaji za rad procjenjuju se pomoću pokazatelja isplativosti rada kao što su participacijska porezna stopa (PPS) i neto stopa zamjene (NSZ), koji se računaju prilikom prelaska u stanje zaposlenosti onih osoba koje primaju naknadu za nezaposlene ili druge vrste socijalnih naknada. Promatrajući prelazak nezaposlenih ili neaktivnih osoba u zaposlenost, PPS mjeri koliki se dio dodatne zarade gubi zbog toga što su povećali porezi i smanjili iznosi socijalnih naknada. Veći iznos PPS-a ukazuje da postoje slabi financijski poticaji za prelazak u zaposlenost, a to za primatelje socijalnih naknada znači veći rizik za upadanjem u zamke nezaposlenosti ili neaktivnosti. Drugi pokazatelj koji se često koristi u literaturi je NSZ, koji mjeri stupanj životnog standarda promatrane osobe i cijelog kućanstva očuvan prilikom promjene stanja iz zaposlenosti u nezaposlenost ili neaktivnost. Mjeri se kao omjer raspoloživog dohotka kućanstva u stanju nezaposlenosti ili neaktivnosti i dohotka u stanju zaposlenosti promatranog člana kućanstva. Što je veći iznos NSZ-a, to je promatrana osoba i

njezino kućanstvo više zaštićeno od gubitka posla, a niži NSZ znači da postoje veći financijski poticaji nezaposlenih ili neaktivnih osoba za prelazak u zaposlenost. Način izračuna oba pokazatelja opisan je u poglavlju 3.1.

Spomenuta dva pokazatelja računaju se na ekstenzivnoj granici ponude rada, na kojoj se mjere financijski poticaji prelaska trenutno nezaposlenih ili neaktivnih osoba u stanje zaposlenosti. Uz ekstenzivnu granicu, u literaturi se spominje i intenzivna granica ponude rada, na kojoj se mjere financijski poticaji trenutno zaposlenih osoba za povećanjem radnih sati, kako bi zaradile veće iznose bruto plaća.[4] Međutim, kako su u fokusu ovog istraživanja samo nezaposlene i neaktivne osobe i njihov hipotetski prelazak u stanje zaposlenosti, promatrat će se samo poticaji za rad na ekstenzivnoj granici ponude rada.

U Hrvatskoj se isplativost rada počela tek nedavno istraživati. Bejaković i sur. (2012) su proveli istraživanje na temelju hipotetskih podataka i utvrdili da u Hrvatskoj postoje kućanstva s vrlo visokim PPS-om. Pokazalo se da visok PPS imaju samohrani roditelji s dvoje djece i parovi s dvoje djece u kojima prvi supružnik razmatra zaposlenje a drugi ne radi. Dakle, to su kućanstva s djecom koja u situaciji kada niti jedan odrasli član ne radi mogu ostvariti veće iznose socijalnih naknada. Spomenute nalaze je potvrdio i Bezeredi (2019) te je dodatno na temelju komparativne analize sa zemljama EU-a utvrdio da se za te tipove kućanstva Hrvatska nalazi među zemljama s najvišim iznosom PPS-a. Laporšek i sur. (2019) su pokazali da i u Sloveniji isti tipovi kućanstva imaju vrlo visok PPS po čemu se za te tipove kućanstva Slovenija nalazi među polovicom zemalja OECD-a i EU-a s većim iznosom PPS-a. Takvi su nalazi dobiveni i u prethodnom istraživanju za Sloveniju, u kojem Dolenc i Vodopivec (2005b) zaključuju da vrlo visok PPS imaju osobe koje žive u kućanstvima s većim brojem uzdržavanih članova i koje prilikom zaposlenja mogu ostvariti primanja iz donjeg dijela distribucije bruto plaće. Suprotne rezultate dobili su Ladányi i Kierzenkowski (2012) za istraživanje provedeno za Mađarsku u kojem se pokazalo da samohrani roditelji i parovi s dvoje djece u kojima prvi supružnik razmatra zaposlenje a drugi ne radi imaju PPS koji je značajno niži od prosjeka OECD-a. Nadalje, za Mađarsku se pokazalo da viši PPS imaju samci i parovi s dvoje djece u kojima jedan supružnik već radi a drugi razmatra zaposlenje, ali i da su ti iznosi približno jednaki prosjeku zemalja OECD-a.

[4] Neki od radova u kojima se analiziraju poticaji za rad na ekstenzivnoj i intenzivnoj granici ponude rada su Saez (2002.); Adam i Browne (2010); Blundell, Bozio i Laroque (2013.); Ranđelović i Žarković-Rakić (2013); Jara i sur. (2019.) itd.

Carone i sur. (2004) su analizom hipotetskih kućanstava za zemlje OECD-a utvrdili da vjerojatnost upadanja u zamku neaktivnosti veća za osobe s nižim stupnjem obrazovanja koje mogu ostvariti samo niske iznose bruto plaće, što takvu skupinu ljudi čini marginalnom skupinom na tržištu rada. Myck i sur. (2015) su na slučaju Poljske istraživali utjecaj provedenih reformi socijalnog i poreznog sustava i znatnog rasta realnih plaća u razdoblju od 2005. do 2011. Rezultati pokazuju da unatoč značajnim poreznim olakšicama koje su uvedene u promatranom razdoblju, financijski poticaji za rad postaju slabiji za kućanstva s djecom i za one koje imaju pravo na socijalne naknade. Međutim, unatoč spomenutim negativnim učincima na isplativost rada određenih skupina kućanstava, ukupni rezultati pokazuju da se zbog značajnog rasta realne plaće tijekom promatranog razdoblja značajno poboljšavaju i financijski poticaji za rad. Navicke i Lazutka (2016) su istraživali isplativost rada u Litvi na intenzivnoj granici ponude rada korištenjem anketnih podataka i na ekstenzivnoj granici koristeći hipotetske podatke. Analiza na intenzivnoj granici ponude rada pokazuje da su financijski poticaji za rad relativno visoki na srednjem i gornjem dijelu distribucije dohotka, dok su oni značajno niži za osobe koje se nalaze u nižim kvintilima ekvivalentnog raspoloživog dohotka. Jako niski poticaji za rad osoba koje se nalaze na dnu dohodovne distribucije rezultat su dominantnog utjecaja novčanih socijalnih naknada, dok učinak poreza na dohodak i doprinosa iz plaće nije posebice izražen. Analiza hipotetskih kućanstava na ekstenzivnoj granici ponude rada je pokazala da su samohrani roditelji i kućanstva s djecom u kojima se prvi odrasli član zapošljava a drugi ne radi najviše izloženi zamkama nezaposlenosti i neaktivnosti. Autori tvrde da su takve obitelji ujedno i najosjetljivije na nagle promjene visine socijalnih naknada u odnosu na plaće.

Galuščák i Pavel (2012) su analizirali NSZ za određene tipove kućanstava na temelju sustava poreza i socijalnih naknada iz 2006. u Češkoj. Pokazali su da veći iznos NSZ-a, odnosno niže financijske poticaje za rad imaju kućanstva s nižim primanjima i kućanstva s djecom i supružnikom koji ne radi. Navode kako na isplativost rada na ekstenzivnoj granici utječe dostupnost i iznosi naknada, od kojih se ističu naknada za nezaposlene i socijalna pomoć. Dušek i sur. (2013) su na temelju anketnih podataka iz SILC istraživanja za Češku za 2011. procijenili empirijske poticaje za rad na intenzivnoj i ekstenzivnoj granici ponude rada. Istraživanje na intenzivnoj granici ponude rada u Češkoj je pokazalo da oko 77% zaposlenih i samozaposlenih ima graničnu efektivnu poreznu stopu veću od 45%, što je gledajući međunarodnu usporedbu jedan od najviših iznosa. Na ekstenzivnoj granici ponude rada su procijenili PPS za prelazak nezaposlenih i neaktivnih osoba u zaposlenost, ali napravili su i

procjene PPS-a za suprotnu situaciju, u kojoj bi trenutno zaposlene ili samozaposlene osobe ostale bez posla. Rezultati sugeriraju da postoji značajan udio osoba s visokim PPS-om, pri čemu PPS veći od 60% ima 8% neaktivnih ili nezaposlenih osoba i 11% zaposlenih i samozaposlenih osoba (Dušek i sur., 2013).

2.3. Politike za povećanje isplativosti rada

Velikodušni sustavi socijalnih naknada su alat koji se često koristi u svrhu smanjenja siromaštva u populaciji. S druge strane, takvi sustavi djeluju negativno na financijske poticaje za ulazak u svijet rada i stvaraju zamke nezaposlenosti i neaktivnosti koja posebno pogađa manje produktivne osobe, odnosno osobe s nižim primanjima. Stoga, Bargain i Orsini (2006) tvrde kako bi socijalni sustavi trebali biti dizajnirani tako da siromašnim osobama osiguravaju dohodak dovoljan za život, a da s druge strane ne djeluju negativno na poticaje za rad. Više od polovine zemalja OECD-a uvelo je politike za povećanje isplativosti rada (engl. *make work pay policies*) koje imaju za cilj povećanje isplativosti rada, odnosno smanjenje siromaštva i promicanje zaposlenosti niskoproduktivnih osoba. Nadalje, Bejaković (2009) navodi da su politike za povećanje isplativosti rada uglavnom usmjerene na poboljšanje financijskih poticaja koji se ostvaruju zaposlenjem u odnosu na materijalna prava iz socijalnog sustava.

Naknade za zaposlene (engl. *in-work benefits*) su glavni instrument politika za povećanje isplativosti rada. Uglavnom se shvaćaju kao novčani transferi u obliku socijalne naknade koja se dodjeljuje zaposlenim osobama s niskim primanjima (Matsaganis i Figari, 2016). Međutim, Immervoll i Pearson (2009) navode da se, radi jednostavnosti prilikom međunarodne usporedbe, u literaturi često pod nazivom naknada za zaposlene stavljaju i neki od elemenata poreznog sustava za koje se smatra da imaju istu funkciju kao i naknade za zaposlene. Primjer spomenutih elemenata su umanjenje obveze poreza na dohodak i doprinosa iz plaće koji se dodjeljuju zaposlenim osobama s niskim primanjima. Dodatno, McKnight i sur. (2016) spominju još nekoliko oblika naknada koje mogu primati zaposlene osobe s niskim primanjima, a to su pomoć u troškovima stanovanja, pomoć u vezi s medicinskih troškova, bonovi za hranu ili pomoć u troškovima školskog obroka, no utjecaj spomenutih naknada na isplativost rada se uglavnom ne istražuje u literaturi.

Glavna karakteristika naknada za zaposlene je da istovremeno teže k postizanju dva cilja: (1) povećanje zaposlenosti uvođenjem dodatnih financijskih poticaja za ostanak u zaposlenosti osoba s niskom plaćom ili za prihvaćanjem posla s niskom plaćom i (2) ublažavanje stope

siromaštva (Leppik, 2006; Immervoll i Pearson, 2009). To su ustvari programi socijalne skrbi koji su dizajnirani tako da pružaju novčanu potporu obiteljima ili osobama s niskim primanjima uz uvjet da je primatelj naknade zaposlen određen broj radnih sati. Naknada se može dodjeljivati ovisno o dohodovnom cenzusu obitelji i tako ovisiti o veličini i strukturi obitelji, ali može biti i provjeravana samo s obzirom na dohodak pojedinca primatelja te naknade. Naknade su kreirane na način da povećavaju prihode kućanstva ili osoba koje ostvaraju niska primanja i tako povećavaju financijske poticaje za ulazak u zaposlenost trenutno neaktivnih ili nezaposlenih osoba koje u tom stanju uživaju prava na naknade iz socijalnog sustava.

Postoje pozitivni i negativni utjecaji naknada za zaposlene na isplativost rada, ovisno o tome dobiva li se naknada prema dohodovnom cenzusu obitelji ili pojedinca. Naknada koja se provjerava s obzirom na dohodak obitelji ima jači utjecaj na smanjenje stope siromaštva od naknade koja se provjerava s obzirom na dohodak pojedinca, budući da bolje cilja obitelji s najnižim primanjima. No valja naglasiti kako je takva naknada uspješna u smanjenju stope siromaštva pod uvjetom da je stopa zaposlenosti u populaciji već visoka (budući da je zaposlenost uvjet za primanje naknade), a trenutna primanja su premala da bi promatrana osoba ili kućanstvo prešlo iznad granice siromaštva. Nadalje, naknada koja je provjeravana s obzirom na dohodak obitelji ima pozitivan utjecaj na povećanje financijskih poticaja za rad na ekstenzivnoj granici ponude rada u obiteljima gdje se prvi odrasli član zapošljava, a drugi ne radi; smanjuje se PPS i povećava se vjerojatnost za prihvaćanje zaposlenja osoba koje trenutno ne rade. Međutim, naknade provjeravane prema dohotku obitelji mogu imati značajan negativan utjecaj na isplativost rada na ekstenzivnoj granici u obiteljima gdje jedan odrasli član već radi, a drugi se zapošljava.

S druge strane, naknada za zaposlene provjeravana s obzirom na dohodak pojedinca ima za sve zaposlene osobe pozitivan utjecaj na povećanje isplativosti rada na ekstenzivnoj granici. Zbog činjenice da se naknada dodjeljuje s obzirom na dohodak pojedinca, takva naknada uglavnom uzrokuje veće proračunske troškove nego ona koja se dodjeljuju prema dohodovnom cenzusu obitelji te ima slabiji utjecaj na smanjenje stope siromaštva. Naknade mogu primati osobe s niskom plaćom koje se nalaze u kućanstvima čiji se raspoloživi dohodak nalazi na sredini ili na vrhu distribucije dohotka, pa takve naknade slabije ciljaju „najugroženija“ kućanstva.

Što se tiče djelovanja poreznog sustava na isplativost rada, Carone (2009) navodi da povećanje ukupnih troškova rada u smislu povećanja doprinosa na plaću smanjuju potražnju za radnom snagom. Nadalje, na strani ponude doprinosi iz plaće i porez na dohodak smanjuju neto prihod i time smanjuju financijske poticaje za rad, posebno osoba s niskim primanjima. Isti autori navode da tipične reforme poreznog sustava koje bi djelovale na povećanje financijskih poticaja za rad uključuju smanjenje poreznog klina za osobe s niskim bruto plaćama kroz proširenje poreznog razreda koji se oporezuje nultom stopom (odnosno, povećanjem osobnog odbitka) i smanjenje obveze poreza na dohodak te doprinosa iz plaće. Istu činjenicu navode Marx i sur. (2012), koji ističu da visok iznos poreznog klina koji se plaća na niže iznose bruto plaća ukazuje na činjenicu da postoji prostor za povećanje dohotka kućanstava s niskim plaćama kroz smanjenje obveze doprinosa iz plaće i poreza na dohodak. Spomenuti autori navode da bi se time povećali financijski poticaji za prelazak iz stanja ovisnosti o socijalnim naknadama u stanje zaposlenosti s nižom bruto plaćom.

Uz naknade za zaposlene koje su glavni instrument politika za povećanje isplativosti rada, u literaturi se spominju i druge politike koje mogu utjecati na povećanje financijskih poticaja za rad. Smanjenje iznosa socijalnih naknada svakako će povećati isplativost rada, no takva politika kosi se s Europskim socijalnim modelom i nije u skladu s Ustavom Europske unije, odnosno Lisabonskim ugovorom čiji članak 34. stavak 3. glasi: „*U svrhu borbe protiv socijalne isključenosti i siromaštva, Unija priznaje i uvažava pravo na socijalnu pomoć i pomoć za stanovanje sa svrhom osiguravanja dostojne egzistencije svima koji ne raspolažu dovoljnim sredstvima, prema uvjetima iz prava Unije i nacionalnim zakonodavstvima i praksi*“ (Rismondo, 2010). Nadalje, McKnight i sur. (2016) navode da su obrazovanje i obuka jedna od učinkovitijih politika na strani ponude rada u cilju sprječavanja zapošljavanja na niskim razinama bruto plaće, što će smanjiti broj ljudi s niskim financijskim poticajima za rad. Autori navode da politika obrazovanja treba osigurati zadovoljavajući kvalifikaciju svim sudionicima na tržištu rada, ali navode da pažnju treba posvetiti i starijim osobama koje se nalaze izvan tržišta rada i koji bi trebali sudjelovati u programima prekvalifikacije i tako osigurati svoje mjesto na tržištu rada.

Sljedeća mjera koja može služiti u svrhu povećanja isplativosti rada su aktivne politike tržišta rada.[5] Glavna uloga aktivnih politika tržišta rada je pružati potporu osobama izvan rada u pronalaženju adekvatnog posla koji će najbolje odgovarati njihovim kvalifikacijama

[5] Više o aktivnim politikama tržišta rada u Hrvatskoj vidjeti u istraživanju Bejaković (2016).

(Europska komisija, 2017d). McKnight i sur. (2016) ističu da bi u svrhu poboljšanja financijskih poticaja za rad takve politike trebale biti definirane tako da uz pomoć pri pronalaženju novog posla pomažu i u sprječavanju zaposlenja uz niže iznose bruto plaće. OECD (2005) pak navodi da učinkovite politike tržišta rada omogućuju osobama izvan rada da „ostanu u kontaktu" s tržištem rada i da time spriječe odlazak u dugotrajnu nezaposlenost te ističu da bi takve politike u kombinaciji s naknadama za zaposlene pružale dobitničku strategiju u poboljšanju isplativosti rada. Dakle, aktivne politike tržišta rada bi povećale vjerojatnost da osobe izvan tržišta rada pronađu zaposlenje, a naknade za zaposlene bi povećale raspoloživi dohodak osoba s nižom plaćom i time povećale financijske poticaje za rad.

Zakonska određena minimalna bruto plaća je također jedan od instrumenata kojim se može djelovati na povećanje financijskih poticaja za rad osoba s niskim primanjima. OECD (2005) tvrdi kako je instrument minimalne plaće puno manje učinkovit u smanjenju stope siromaštva nego dobro dizajnirana naknada za zaposlene, te da povećanje minimalne plaće uzrokuje povećanje troškova za poslodavce koji zapošljavaju uz minimalnu plaću, što bi moglo utjecati na povećanje vjerojatnosti za otpuštanje nisko kvalificiranih radnika. Slab utjecaj minimalne plaće na smanjenje siromaštva su potvrdili Mrnjavac i Blažević (2014) i Nestić i Blažević Burić (2018), koji su na slučaju Hrvatske utvrdili da politika minimalne plaće nije učinkovita u smanjenju stope siromaštva te da ima ograničen utjecaj na dohodovnu nejednakost. Što se tiče utjecaja minimalne plaće na isplativost rada, OECD (2005) ističe da bi najučinkovitija politika bilo kombinirano djelovanje oba instrumenata. Naime, izolirano djelovanje naknada za zaposlene bez postavljanja minimalne bruto plaće može dovesti do činjenice da poslodavci počinju smanjivati bruto plaće, što može biti jedan od potencijalnih odgovora poslodavaca na povećanje ponude rada uzrokovane uvođenjem naknada za zaposlene. U tom slučaju bi postavljanje minimalne plaće na odgovarajuću razinu omogućilo nisko plaćenim radnicima da iskoriste sve blagodati naknade za zaposlene. Da bi to osigurale, neke zemlje poput UK-a, SAD-a, Irske i Novog Zelanda su uvele instrument minimalne plaće kao komplement postojećim naknadama za zaposlene. McKnight i sur. (2016) navode da je glavni motiv povećanja minimalne bruto plaće u UK-u 2016. bio sprječavanje činjenice da se nisko plaćeni poslovi subvencioniraju od strane poreznih obveznika kroz naknade za zaposlene pa se povećanjem razine minimalne bruto plaće pokušalo ograničiti spomenute negativne posljedice uvođenja naknada za zaposlene.

Vratimo se naknadama za zaposlene koje su glavni instrument politika za povećanje isplativosti rada. Takve naknade se pružaju u obliku novčane potpore niskokvalificiranim

zaposlenim osobama i tako potiču njihovo zapošljavanje uz istovremeno održavanje izdašnih naknada socijalne pomoći. Prve zemlje koje su uvele naknade za zaposlene s niskim primanjima bile su SAD, gdje je uvedena naknada pod nazivom EITC (engl. *Earned Income Tax Credit*), i UK s naknadom WFTC (engl. *Working Family Tax Credit*), a obje naknade se dodjeljuju s obzirom na dohodovni cenzus obitelji. Također, zemlje poput Irske i Novog Zelanda imaju vrlo dugu povijest postojanja naknada za zaposlene, a naknade se također dodjeljuju prema dohodovnom cenzusu obitelji. Većina empirijskih istraživanja provedena je za naknade EITC i WFTC. Pokazalo se da te naknade uglavnom potiču zapošljavanje prvog odraslog člana u kućanstvu (Blundell 2000; Blundell i Hoynes 2004; Eissa i Hoynes, 2004; Brewer i sur., 2006), ali istraživanja koja su proveli Brewer i sur. (2006) i Eissa i Hoynes (2004) su pokazala da spomenute naknade stvaraju negativan utjecaj na financijske poticaje za rad prilikom zapošljavanje druge odrasle osobe u kućanstvu.

Kako bi izbjegli negativne poticaje za rad parova u kojima se i drugi supružnik zapošljava, zemlje poput Australije, Kanade, Belgije i Francuske su uvele naknade za zaposlene koje se dodjeljuju s obzirom na dohodak pojedinca, čime se pažnja posvećuje dohotku primatelja naknade umjesto cjelokupnom dohotku kućanstva. Stoga bi takvi programi mogli biti učinkovita alternativa obiteljskim tipovima naknada. Međutim, Bargain i sur. (2010) spominju da i kod individualnih naknada postoje nekoliko otvorenih pitanja o optimalnosti strukture takve politike. Preciznije, spomenuti autori navode kako većina naknada koje se provjeravaju s obzirom na dohodak pojedinca kombiniraju pozitivne učinke na ekstenzivnoj i negativne učinke na intenzivnoj granici ponude rada. Jedan od primjera naknade provjeravane uz dohodak pojedinca je smanjenje obveze doprinosa iz plaće koje je uvedeno u Njemačkoj u 2003. u sklopu reforme „Mini-jobs“ i na koje imaju pravo osobe s niskim primanjima. Steiner i Wrohlich (2005) su istraživali utjecaj spomenute politike na isplativost rada i učinke na ponudu rada i utvrdili da negativni učinci na intenzivnoj granici ponude rada premašuju male pozitivne učinke koji se pojavljuju na ekstenzivnoj granici. Time su potvrdili da spomenuta politika nije učinkovita u smislu povećanja zaposlenosti ljudi s niskim kapacitetom zarade.

Osim analiziranja već uvedenih reformi za poboljšanje isplativosti rada u literaturi je vrlo popularno istraživanje utjecaja hipotetskih reformi na isplativost rada. Figari i sur. (2010) su analizirali uvođenje hipotetskih naknada za zaposlene provjeravanih prema dohotku obitelji i pojedinca u četiri zemlje – Portugalu, Grčkoj, Italiji i Španjolskoj. Jedan tip naknade je simuliran po uzoru na britanski WFTC, a drugi tip naknade koja se provjerava prema dohotku pojedinca je uveden u obliku potpore na nisku plaću. Pokazalo se da su naknade provjeravane

s obzirom na dohodak pojedinca efikasnije u poboljšanju poticaja za rad od naknada koje se dodjeljuju s obzirom na dohodak obitelji, što se osobito pokazalo za žene u Francuskoj i Italiji koje žive u paru i čija je stopa zaposlenosti daleko ispod prosjeka EU-a.

Bargain i sur. (2010) na slučaju Njemačke analiziraju utjecaj na isplativost rada dviju politika koje se dodjeljuju s obzirom na dohodak pojedinca. Analizira se postojeća politika u Njemačkoj koja je uvedena u sklopu reforme „Mini-job" i koja se odnosi na smanjenje obveze doprinosa iz plaće te hipotetska reforma koja je kreirana po uzoru na belgijski „*Employment Bonus*" koji je također definiran kao odbitak od obveze doprinosa iz plaće. Razlika između dviju politika je u definiranju dohotka pojedinca koji se uzima u obzir prilikom određivanja dohodovnog cenzusa; postojeća politika u obzir uzima ukupnu plaću pojedinca, dok belgijski tip politike u obzir uzima plaću po satu i broj sati rada. Za postojeću politiku uvedenu u sklopu „Mini-job" reforme se, kao i u radu Steiner i Wrohlich (2005), pokazalo da negativni poticaji na intenzivnoj granici ponude rada prevladaju nad pozitivnim utjecajem na ekstenzivnoj granici. Naime, kako bi maksimizirale dobitak od spomenute reforme, osobe koje trenutno rade mogu smanjiti svoje sate rada, što djeluje negativno na poticaje za rad na intenzivnoj granici. Kako bi se izbjegli spomenuti negativni poticaji na intenzivnoj granici uzrokovani smanjenjem broja sati rada, belgijski model reforme u dohodovnom cenzusu u obzir uzima plaću po satu i broj sati rada. Tako belgijski tip politike ovisi o satnici i broju sati radi u smislu da će primatelj dobiti dvostruko veći iznos naknade ako radi puno radno vrijeme nego u slučaju da radi na pola radnog vremena. Uvođenje belgijskog tipa reforme u Njemačku pokazuje da takav tip reforme izbjegava negativne učinke na intenzivnoj granici i ima veći pozitivan utjecaj na ekstenzivnoj granici za razliku od postojeće reforme u Njemačkoj.

Vandelannoote i Verbist (2020) su proučavali utjecaj različitih dizajna naknada za zaposlene na siromaštvo i poticaje za rad u Belgiji, Italiji, Poljskoj i Švedskoj. Pokazalo se da postojeće i hipotetske naknade za zaposlene općenito imaju pozitivan utjecaj na ekstenzivnoj granici ponude rada, a taj utjecaj je jači kod naknada koje se provjeravaju s obzirom na dohodak pojedinca nego kod naknada provjeravanih s obzirom na dohodak obitelji. Spomenuti autori napominju da je to rezultat koji se često dobiva u literaturi. Rezultati također pokazuju da se jačina učinka znatno razlikuje među zemljama, učinci na poticaje za rad su izraženiji za Belgiju i Švedsku, dok se za Poljsku radi o zanemarivim učincima. Utjecaj na stopu siromaštva se razlikuje ovisno o dizajnu naknade, pri čemu naknade provjeravane s obzirom na dohodak obitelji uzrokuju veće smanjenje stope siromaštva od naknada provjeravanih prema dohodovnom cenzusu pojedinca.

De Luca i sur. (2014) na uzorku parova u Italiji analiziraju uvođenje dviju naknada za zaposlene koje su dizajnirane po uzoru na američki EITC i britanski WTC, no uz standardni dizajn ovih dviju naknada uvodi se i premija za zapošljavanje drugog supružnika u obitelji. Spomenuta premija se uvodi kako bi se prevladali potencijalni negativni utjecaji koje prilikom zapošljavanja drugog supružnika u obitelji uzrokuju naknade kao što su EITC i WTC, koje su provjeravane prema dohodovnom cenzusu obitelji. Pokazalo se da spomenute naknade, uz prikladan iznos premija za drugog zaposlenog supružnika u obitelji, mogu u velikoj mjeri poboljšati redistributivne učinke i isplativost rada parova u Italiji. Rezultati sugeriraju da je redizajnirani EITC učinkovitiji od WTC-a u poticanju zaposlenosti, dok je redizajnirani WTC učinkovitiji u smanjenju stope siromaštva. Slično istraživanje proveli su Kurowska i sur. (2017), koji za parove u Poljskoj analiziraju utjecaj povećanja izdašnosti postojećih naknada za zaposlene i uvođenje premije za drugog zaposlenog supružnika na ponudu rada. Rezultati pokazuju da spomenuti redizajn postojećih naknada za zaposlene, koje su usmjerene na obitelji s djecom i niskim primanjima, može biti učinkovita politika za povećanje stope zaposlenosti majki. Spomenuti autori napominju da bi uvođenje premije za drugog zaposlenog supružnika u obitelji, koja bi se dodijelila obiteljima s niskim primanjima, moglo biti uspješno sredstvo za smanjenje siromaštva djece koje bi nastalo kao rezultat izravne novčane potpore i veće aktivnost roditelja na tržištu rada.

3. METODOLOGIJA IZRAČUNA POKAZATELJA ISPLATIVOSTI RADA I OPIS PODATAKA

U ovom dijelu definiraju se pokazatelji isplativosti rada, opisuje se metodologija njihovog izračuna te se definiraju izvori podataka koji se koriste u analizi (anketni i hipotetski). Opisuju se i regresijski modeli koji će se koristiti u disertaciji, a to su Heckmanov selekcijski model, za procjenu bruto plaća neaktivnih i nezaposlenih osoba, i logit model, kojim se utvrđuju prediktori visokih iznosa pokazatelja isplativosti rada.

3.1. Pokazatelji isplativosti rada

U radu će se koristiti dva najpoznatija pokazatelja isplativosti rada na ekstenzivnoj granici ponude rada, a to su participacijska porezna stopa (engl. *participation tax rate*) i neto stopa zamjene (engl. *net replacement rate*). Spomenuti pokazatelji mjere financijske poticaje trenutno nezaposlenih ili neaktivnih osoba za prelazak u hipotetsko stanje zaposlenosti. U ovom istraživanju se pod neaktivne osobe ne ubrajaju umirovljenici, osobe nesposobne za rad, te učenici, studenti i osobe na osposobljavanju. Dakle, u smislu istraživanja isplativosti rada, u daljnjem tekstu se neaktivnima smatraju PZOIR osobe, definirane u poglavlju 2.1.

3.1.1. Participacijska porezna stopa

Participacijska porezna stopa (PPS) mjeri koliki se udio bruto plaće gubi prilikom prelaska promatrane osobe iz stanja nezaposlenosti ili neaktivnosti u zaposlenost zbog toga što se povećavaju porezi i smanjuju socijalne naknade (Jara i sur., 2019). PPS se procjenjuje prema sljedećoj formuli

$$PPS_i = 1 - \frac{Y_i^1 - Y_i^0}{X_i^1 - X_i^0}, \tag{3.1}$$

gdje Y_i^1 označava raspoloživi dohodak kućanstva u stanju kada je promatrana osoba i zaposlena, a Y_i^0 je raspoloživi dohodak kućanstva u slučaju kada bi osoba i ostala nezaposlena ili neaktivna. Analogno, X_i^1 je bruto dohodak kućanstva u stanju kada je promatrana osoba i zaposlena, a X_i^0 je bruto dohodak kućanstva u slučaju kada bi osoba i ostala nezaposlena ili neaktivna. Visoki iznosi PPS-a (oko jedan) ukazuju na niske poticaje za rad, a iznosi PPS-a veći od jedan znače da bi promatrana osoba u stanju zaposlenosti imala manji raspoloživi dohodak nego u situaciji kada bi ostala izvan rada.

Metodologija izračuna PPS-a na temelju anketnih podataka se provodi na sljedeći način. Analizira se prelazak trenutno nezaposlenih ili neaktivnih osoba u zaposlenost na puno radno vrijeme. Prvo se pomoću mikrosimulacijskih modela miCROmod-a i EUROMOD-a[6] računa raspoloživi dohodak kućanstva Y_i^0 u stvarnom stanju kada promatrana osoba ne radi, a potom se računa raspoloživi dohodak kućanstva Y_i^1 u hipotetskom stanju kada bi se promatrana osoba zaposlila na puno radno vrijeme. Međutim, prije izračuna raspoloživog dohotka kućanstva Y_i^1 potrebno je predvidjeti bruto plaću X_i^1 koju bi osoba i mogla zaraditi kada bi se zaposlila na puno radno vrijeme. Naime, u anketnim podacima ne postoje informacije o bruto plaći X_i^1 koju bi osoba i mogla zaraditi u hipotetskom stanju zaposlenosti na puno radno vrijeme. Plaće se predviđaju korištenjem Heckmanovog selekcijskog modela, koji će biti detaljnije opisan u dijelu 3.2. U slučaju da unutar kućanstva postoje dvije ili više neaktivnih ili nezaposlenih osoba, PPS se zasebno računa za svaku takvu osobu, uz pretpostavku da karakteristike ostalih članova u kućanstvu ostaju nepromijenjene. Dodatno, za neaktivne i nezaposlene osobe koje ostvaruju dohodak od neformalne samozaposlenosti ili ugovora o djelu se pretpostavlja da u hipotetskom stanju zaposlenosti na puno radno vrijeme odustaju od neformalne djelatnosti pa gube te prihode. Metodologija izračuna PPS-a na temelju hipotetskih podataka provodi se prema identičnom obrascu uz iznimku da se preskače korak u kojem je potrebno procijeniti bruto plaću X_i^1, budući da se u hipotetskim kućanstvima ta plaća zadaje od strane autora istraživanja.[7]

Kako bi se otkrio utjecaj svake komponente poreznoga i socijalnog sustava na isplativost rada, potrebno je napraviti dekompoziciju PPS-a. Raspoloživi dohodak kućanstva može se izraziti pomoću izvornog dohotka (ukupnog dohotka prije poreza i naknada; oznaka O), socijalnih naknada (B), poreza (T) i doprinosa iz plaće (D), pa se jednakost (3.1) može dekomponirati na sljedeći način (Jara i sur., 2019)

$$PPS_i = 1 - \frac{\left(O_i^1 - O_i^0\right) + \left(B_i^1 - B_i^0\right) - \left(T_i^1 - T_i^0\right) - \left(D_i^1 - D_i^0\right)}{X_i^1 - X_i^0}. \qquad (3.2)$$

Budući da je promjena izvornog dohotka, $\left(O_i^1 - O_i^0\right)$, jednaka promjeni bruto dohotka, $\left(X_i^1 - X_i^0\right)$, izraz (3.2) poprima sljedeći oblik

[6] Više o mikrosimulacijskim modelima miCROmod-u i EUROMOD-u vidjeti u poglavlju 3.3.

[7] Za detaljniji opis hipotetskih kućanstava vidjeti poglavlje 3.3.

$$
\begin{aligned}
PPS_i &= -\frac{\left(B_i^1 - B_i^0\right) - \left(T_i^1 - T_i^0\right) - \left(D_i^1 - D_i^0\right)}{X_i^1 - X_i^0} = \\
&= \frac{\left(B_i^0 - B_i^1\right)}{X_i^1 - X_i^0} + \frac{\left(T_i^1 - T_i^0\right)}{X_i^1 - X_i^0} + \frac{\left(D_i^1 - D_i^0\right)}{X_i^1 - X_i^0} = \\
&= PPS_i^B + PPS_i^T + PPS_i^D.
\end{aligned} \tag{3.3}
$$

Komponenta PPS_i^B mjeri doprinos socijalnih naknada u ukupnom PPS-u, odnosno promjenu iznosa socijalnih naknada na razini kućanstva izraženu kao postotak promjene bruto dohotka do koje dolazi prilikom prelaska iz stanja nezaposlenosti ili neaktivnosti u zaposlenost. Komponente PPS_i^T i PPS_i^D mjere doprinos poreza na dohodak i doprinosa iz plaće ukupnom PPS-u.

3.1.2. Neto stopa zamjene

Neto stopa zamjene (NSZ) se procjenjuje kao omjer raspoloživog dohotka kućanstva u stanju kada je promatrani član kućanstva nezaposlen ili neaktivan i raspoloživog dohotka kućanstva u stanju kada se taj član zaposli (Immervoll i sur., 2004; Browne i sur., 2018; Jara i Tumino, 2018). Dakle, NSZ uspoređuje ukupni raspoloživi dohodak kućanstva u dva različita stanja u kojima se može nalaziti promatrani član kućanstva, u stanju nezaposlenosti ili neaktivnosti i u hipotetskom stanju zaposlenosti i na taj način mjeri poticaje za rad s kojima bi se suočile neaktivne ili nezaposlene osobe prilikom prelaska u stanje zaposlenosti. NSZ se definira na sljedeći način:

$$
NSZ_i = \frac{Y_i^0}{Y_i^1}, \tag{3.4}
$$

pri čemu Y_i^1 označava raspoloživi dohodak kućanstva u stanju kada je promatrana osoba i zaposlena, a Y_i^0 je raspoloživi dohodak kućanstva u stanju nezaposlenosti ili neaktivnosti osobe i. Za kućanstva s više neaktivnih ili nezaposlenih osoba, NSZ se zasebno računa za svaku takvu osobu u kućanstvu, uz uvjet da se karakteristike ostalih članova u kućanstvu ne mijenjanju. Što je NSZ bliže vrijednosti jedan to su manji financijski poticaji za prelazak iz nezaposlenosti ili neaktivnosti u zaposlenost, a iznos veći od jedan znači da je raspoloživi dohodak kućanstva u stanju nezaposlenosti ili neaktivnosti veći nego u stanju zaposlenosti. Metodologija izračuna je ista kao i kod procjene PPS-a, odnosno za izračun raspoloživog dohotka kućanstva Y_i^0 i Y_i^1 se koriste miCROmod-a ili EUROMOD, a bruto plaće u hipotetskom stanju zaposlenosti se procjenjuju koristeći Heckmanov selekcijski model.

3.1.3. Glavne razlike između PPS-a i NSZ-a

Glavna razlika između spomenuta dva pokazatelja je ta da PPS mjeri utjecaj poreza i socijalnih naknada na isplativost rada, dok NSZ mjeri jačinu poticaja za rad (Adam i Browne, 2010). Općenito, analiziranje poticaja za rad na temelju PPS-a i NSZ-a često dovodi do istih zaključaka, ali u nekim slučajevima može doći do različitih zaključaka te ih se ne može u punom smislu promatrati kao istoznačnice. Na primjer, osoba koja zaposlenjem može ostvariti samo niže vrijednosti bruto plaće i koja živi u kućanstvu s osobom koja ostvaruje visok dohodak ima vrlo visok NSZ, dok ta ista osoba ima nizak PPS. Nadalje, povećanje dohotka ostalih članova kućanstva će povećati NSZ, dok će PPS ostati nepromijenjen. Dakle, povećanje raspoloživog dohotka ostalih članova kućanstva će prema NSZ-u ukazati na činjenicu da postoje slabiji poticaji za rad, dok će prema PPS-u poticaji za rad ostati nepromijenjeni (Adam i sur., 2006).

Budući da je glavni cilj rada usmjeren na analiziranje utjecaja sustava poreza i socijalnih naknada na isplativost rada, veća pažnja je usmjerena na izračun PPS-a, dok se NSZ računa kao alternativni pokazatelj isplativosti rada. Nadalje, NSZ je prikladan pokazatelj za usporedbu ukupnog raspoloživog dohotka u stanju kada je promatrana osoba izvan rada i u stanju zaposlenosti. Međutim, ako je cilj analizirati uspješnost sustava poreza i socijalnih naknada u smislu održavanja pozitivnih poticaja za rad, NSZ neće biti pogodna mjera jer na njenu visinu utječu i ostali dohoci koji će posljedično zamagliti čisti utjecaj sustava poreza i socijalnih naknada na isplativost rada (O'Donoghue, 2011). Dakle, veća pozornost je posvećena izračunu PPS-a, koji je u mogućnosti izolirati utjecaj sustava poreza i socijalnih naknada na poticaje za rad.

3.2. Regresijski modeli korišteni u analizi

U disertaciji se koriste dva regresijska modela, a to su Heckmanov selekcijski model i logit model. Heckmanov model se koristi za procjenu bruto plaća po satu neaktivnih i nezaposlenih osoba za koje u anketnim podacima ne postoje podaci o bruto plaći, a rezultati će biti prikazani u dijelu 3.3.2. S druge strane, pomoću logit modela se procjenjuju prediktori visokog PPS-a, koji će biti opisani u poglavljima 4.3. i 4.6.

3.2.1. Heckmanov selekcijski model

Prethodno opisani pokazatelji isplativosti rada na ekstenzivnoj granici ponude rada, PPS i NSZ, računaju se za trenutno neaktivne ili nezaposlene osobe. Budući da u anketnim podacima ne postoje informacije u bruto plaći tih osoba, njihove plaće je potrebno predvidjeti. Postoje mnoge

metode za predviđanje bruto plaća osoba koji ne rade.[8] Adam i sur. (2006) spominju kako je iznose bruto plaća osoba koje ne rade najjednostavnije predvidjeti na način da se jednadžba plaće najprije procijeni za osobe koje trenutno rade, a potom se bruto plaće neaktivnih i nezaposlenih osoba predviđaju na temelju njihovih obilježja koristeći prethodno procijenjenu jednadžbu plaće. Međutim, isti autori spominju kako takav pristup ne rješava problem odabira uzorka (engl. *sample selection problem*). Naime, odluka o ulasku u svijet rada ne može se promatrati kao slučajna odluka, budući da mogu postojati mnoga obilježja koja utječu na odluku o prihvaćanju posla. Na primjer, ako odluka o prihvaćanju posla ovisi o financijskim karakteristikama, za osobe koje mogu ostvariti manje financijske koristi od zapošljavanja bit će manje vjerojatno da prihvate novi posao. Dakle, ako postoje čimbenici koji ne mogu biti primijećeni od strane analitičara i koji utječu na visinu bruto plaće, za osobe koje imaju ista preostala obilježja, procijenjena plaća za one koji trenutno rade će se razlikovati od procijenjene plaće osoba koje ne rade (Adam i sur., 2006). Stoga se za procjenu bruto plaća u literaturi koristi Heckmanov selekcijski model (engl. *Heckman selection model*) koji identificira i uklanja problem odabira uzorka.[9] Dakle, Heckmanov selekcijski model uključuje istovremeno određivanje oba odnosa – vjerojatnost zapošljavanja promatranih osoba i procjenu plaće.

Heckmanov selekcijski model koji će se u radu koristiti za predviđanje bruto plaće po satu w_i definiran je sljedećim jednadžbama (Heckman, 1976; Heckman, 1979; Wooldridge, 2002; Breunig i Mercante, 2010)[10]

$$\ln(w_i) = X_i\beta + \rho\lambda(Z_i\hat{\gamma}) + u_i, \tag{3.5}$$

gdje se γ procjenjuje pomoću jednadžbe

$$y_i^* = Z_i\gamma + v_i. \tag{3.6}$$

Dakle, prvo se procjenjuje jednadžba (3.6), koja je zapravo model za procjenu vjerojatnosti zaposlenosti. Vektor varijabli Z_i u jednadžbi (3.6) obuhvaća skup nezavisnih varijabli o kojima ovisi vjerojatnost da se pojedina osoba zaposli, γ je vektor parametara koji se procjenjuju, a v_i su greške relacije. Potom se, koristeći procijenjene parametre $\hat{\gamma}$ iz jednadžbe (3.6), predviđa

[8] Više o metodama za predviđanje bruto plaća osoba koje ne rade vidjeti u istraživanju Bezeredi i Urban (2016).

[9] Za primjere radova u kojima se za procjenu bruto plaća osoba izvan rada koristi Heckmanov selekcijski model, vidjeti Bargain i Orsini (2006), Bargain i sur. (2010), O'Donoghue (2011), Kališkova (2015), Bartles i Pestel (2016), Collado i sur. (2017) i Collado (2018).

[10] Detaljniji opis Heckmanovog selekcijskog modela može se pronaći i u udžbenicima Amemiya (1985), Verbeek (2004), Cameron i Trivedi (2005) i Green (2008).

logaritam bruto plaće po satu u jednadžbi (3.5). Pretpostavlja se da greške relacije u_i i v_i imaju bivarijantnu normalnu distribuciju s očekivanjem nula, odnosno da vrijedi $v_i \sim$, $u_i \sim$) i $corr(v_i, u_i) = \rho.$ Vektor varijabli X_i u jednadžbi (3.5) obuhvaća skup nezavisnih varijabli o kojima ovisi visina bruto plaće po satu, a sve varijable sadržane u X_i iz jednadžbe (3.5) moraju ujedno biti sadržane i u Z_i iz jednadžbe (3.6). Izraz $\lambda(Z_i\hat{\gamma})$ se naziva „Heckmanova lambda“, a definira se na sljedeći način

$$\lambda(Z_i\hat{\gamma}) = \frac{\phi(Z_i\hat{\gamma})}{\Phi(Z_i\hat{\gamma})}, \tag{3.7}$$

gdje je $\phi(\cdot)$ funkcija gustoće jedinične (standardizirane) normalne distribucije, a $\Phi(\cdot)$ je kumulativna funkcija jedinične (standardizirane) normalne distribucije.

3.2.2. Logit model

Logit model će se koristiti za predviđanje odrednica vrlo visokog PPS-a. Zavisna varijabla y je binarna varijabla koja poprima vrijednost 1 ako je PPS veći ili jednak 70%, dok za niže razine PPS-a poprima vrijednost 0.

Prilikom definiranja modela, bez gubitka općenitosti, može se pretpostaviti da zavisna varijabla y poprima vrijednost 1 s vjerojatnošću p, a vrijednost 0 poprima s vjerojatnošću $1-p$. Regresijski model nastaje parametrizacijom vjerojatnosti p koja ovisi o regresorskom vektoru varijabli X_i i vektoru parametara β (Cameron i Trivedi, 2005). Za svaku osobu i procjena vjerojatnosti se definira na sljedeći način

$$\begin{aligned} p_i = \text{Prob}(y_i = 1) = \text{Prob}[x_i\beta + \varepsilon_i > 0] = \text{Prob}[\varepsilon_i > -x_i\beta] = \\ = 1 - \text{F}(-x_i\beta), \end{aligned} \tag{3.8}$$

pri čemu je $F(\cdot)$ kumulativna funkcija distribucije slučajne pogreške ε (Maddala, 2001). Pod pretpostavkom da je distribucija od ε simetrična, vrijedi

$$F(x_i\beta) = 1 - F(-x_i\beta), \tag{3.9}$$

pa se izraz (3.8) može preformulirati na sljedeći način

$$p_i = F\left(x_i\beta\right). \tag{3.10}$$

Nadalje, kod logit modela se pretpostavlja da slučajna pogreška ε slijedi logističku distribuciju pa funkcija $F(\cdot)$ poprima sljedeći izraz

$$F\left(x_i\beta\right) = \frac{\exp\left(x_i\beta\right)}{1+\exp\left(x_i\beta\right)}. \tag{3.11}$$

Stoga se logit model definira sljedećim izrazom

$$p_i = \frac{\exp\left(x_i\beta\right)}{1+\exp\left(x_i\beta\right)}. \tag{3.12}$$

Za svaku osobu i, granični utjecaj jedinične promjene j-te nezavisne varijable na smjer i veličinu kretanja zavisne varijable y je dan sljedećim izrazom

$$\frac{\partial p_i}{\partial x_{ij}} = \beta_j p_i\left(1-p_i\right). \tag{3.13}$$

3.3. Podaci i varijable

Prilikom analize pokazatelja isplativosti rada koriste se dva izvora podataka, hipotetski podaci i reprezentativni anketni podaci. Što se tiče hipotetskih podataka, konstruirat će se šest tipova hipotetskih kućanstava, a kao podloga se koriste radovi Immervoll i sur. (2004), Carone i sur. (2009), Brewer i sur. (2010), Navicke i sur. (2016) i Bezeredi (2019):

Tip 1: Samac;

Tip 2: Samohrani roditelj s dvoje djece;

Tip 3: Par bez djece u kojemu prvi supružnik razmatra zaposlenje, a drugi ne radi;

Tip 4: Par s dvoje djece u kojemu prvi supružnik razmatra zaposlenje, a drugi ne radi;

Tip 5: Par bez djece u kojemu prvi supružnik razmatra zaposlenje, a drugi je već zaposlen uz bruto plaću koja iznosi 75% prosječne bruto plaće (PBP);

Tip 6: Par s dvoje djece u kojemu prvi supružnik razmatra zaposlenje, a drugi je već zaposlen uz bruto plaću od 75% PBP-a.

U navedenih šest tipova kućanstava pretpostavlja se da prvi odrasli član ima 38, a drugi 43 godine, a u kućanstvima tipa 4 i 6 djeca imaju 4 i 7 godina. Unutar svakog kućanstva samo jedan odrasli član mijenja stanje na tržištu rada te može biti neaktivan (bruto plaća mu iznosi nula) ili zaposlen (uz bruto plaću veću od 40% PBP-a), dok obilježja ostalih članova u

kućanstvu ostaju konstantna. Odrasli članovi kućanstva kada su zaposleni primaju samo plaću od nesamostalnog rada, odnosno ne zarađuju tržišni dohodak iz ostalih izvora, a u stanju neaktivnosti ne ostvaruju pravo na naknadu za nezaposlene.

Budući da se u istraživanju koriste hipotetski i anketni podaci, važno je napomenuti prednosti i nedostatke korištenja svakog izvora podataka. Izračuni na temelju hipotetskih podataka za odabrani tip kućanstava pružaju detaljan uvid u situaciju kako određene komponente poreznog i socijalnog sustava utječu na iznos pokazatelja isplativosti rada, a glavna prednost je da se takva metoda može primijeniti za razne tipove kućanstava (Immervoll i sur., 2004). Također, prednosti korištenja hipotetskih podataka su neovisnost rezultata o strukturi populacije, pa takvi rezultati prikazuju samo „čisti" utjecaj određenih politika i mogu biti korisni za komparativnu analizu među zemljama kojoj je cilj utvrditi kako se određene komponente sustava poreza i socijalnih naknada razlikuju među zemljama (Burlacu i sur., 2014; Gasior i Recchia, 2019). Međutim, analize na temelju hipotetskih kućanstava ne daju odgovor na pitanja kako sustavi poreza i socijalnih naknada utječu na isplativost rada u određenoj zemlji, odnosno ne otkrivaju koliki udio populacije ima visoke iznose pokazatelja isplativosti rada, te koliko će biti „dobitnika" ili „gubitnika" uslijed provedbe neke reforme sustava poreza i socijalnih naknada. Spomenute odgovore moguće je dobiti upotrebom reprezentativnih mikropodataka (Carone i sur., 2004), a to je ujedno i glavna prednost korištenja anketnih u odnosu na hipotetske podatke.

Anketni podaci za Hrvatsku i Sloveniju će se detaljnije opisati i analizirati u dijelu 3.3.1., nakon čega se u dijelu 3.3.2. prikazuju rezultati Heckmanovog selekcijskog modela, koji se koristi za predviđanje bruto plaća neaktivnih i nezaposlenih osoba.[11] Na koncu poglavlja daje se opis mikrosimulacijskih modela poreza i socijalnih naknada koji će se koristiti u analizi pokazatelja isplativosti rada na temelju oba spomenuta izvora podataka.

3.3.1. Anketni podaci

U ovom istraživanju se za Hrvatsku koriste podaci iz Ankete o dohotku stanovništva (ADS) za 2016., a za Sloveniju se koriste podaci iz EU-SILC ankete (engl. *Statistics on Income and Living Conditions*) za 2016. EU-SILC je obvezno istraživanje koje za sve zemlje EU-a omogućuje komparativnu analizu statistike dohotka, pokazatelja siromaštva i socijalne isključenosti. Anketa se provodi na godišnjoj razini koristeći uzorak slučajno odabranih privatnih kućanstava.

[11] Kada se procjenjuju pokazatelji isplativosti rada na temelju anketnih podataka potrebno je predvidjeti bruto plaće osoba koje trenutno ne rade jer za njih ne postoje podaci o bruto plaći u anketi.

ADS je od 2010. u statističkom sustavu Republike Hrvatske, a ujedno je usklađen s metodologijom Eurostata koja se primjenjuje za istraživanja EU-SILC (DZS, 2017). Državni zavod za statistiku (DZS) u Hrvatskoj ustvari koristi podatke iz ADS-a kako bi konstruirao EU-SILC podatke/varijable za Hrvatsku. Slijedom toga, EU-SILC varijable su agregirane na višem stupnju, a podaci iz ADS-a nešto su detaljniji. Veća detaljnost je i glavni razlog korištenja ADS-a za Hrvatsku umjesto EU-SILC podataka. Dakle, u smislu komparativne analize između Hrvatske i Slovenije (ali i ostalih zemalja EU-a), podaci ADS-a za Hrvatsku su usporedivi s podacima EU-SILC za Sloveniju (i ostale zemlje EU-a).

Spomenute ankete sadrže podatke o bruto i neto dohotku cjelokupnog kućanstva i svakog pojedinog člana kućanstva. Podaci o dohotku podijeljeni su na više kategorija; sastoje se od dohotka koji se ostvaruje na tržištu rada (npr. dohodak od zaposlenosti, samozaposlenosti i ugovora o djelu), dohotka koji se ne ostvaruje direktno na tržištu rada (npr. dohodak od kapitala i imovine), prihoda od različitih državnih socijalnih naknada (npr. naknade socijalne pomoći i naknade iz socijalnog osiguranja) i privatnih transfera (npr. alimentacija). Nadalje, podaci sadrže informacije o stupnju obrazovanja osoba, statusu aktivnosti i zaposlenosti, materijalnom i financijskome statusu kućanstva te informacije o vlastitom zdravstvenom stanju, ali i mnogim drugim demografskim i socio-ekonomskim obilježjima osoba i kućanstava (DZS, 2017). Referentno razdoblje za varijable o dohotku je prethodna kalendarska godina, tako se u ovom istraživanju sve varijable o dohotku odnose na 2015.

3.3.1.1. Definiranje neaktivnih i nezaposlenih osoba u smislu procjene isplativosti rada

U svrhu istraživanja isplativosti rada najprije se definiraju „fleksibilne“ osobe, koje čine žene u dobi od 18 do 60 i muškarci u dobi od 18 do 65 godina koji su tijekom 12 mjeseci u godini bili u jednom od sljedeća tri stanja: zaposleni, nezaposleni ili neaktivni.[12] Fleksibilne osobe ne moraju nužno biti samo u jednom od spomenuta tri stanja tokom cijele godine, nego mogu prelaziti u bilo koje od ta tri stanja. Međutim, ako je osoba barem jedan mjesec provela u nekom drugom stanju (umirovljenik, student, itd.), takva osoba se smatra nefleksibilnom. Dodatno, sve žene s djecom do navršene prve godine života smatraju se nefleksibilnima. Za fleksibilne osobe se smatra da su zaposlene ako rade više od 5 sati tjedno, a ostale fleksibilne osobe se smatraju nezaposlenim ili neaktivnim. Budući da se poticaji za rad računaju samo na ekstenzivnoj granici ponude rada, pokazatelji isplativosti rada PPS i NSZ računat će se samo za fleksibilne

[12] Uz određene modificirane kriterije odabira fleksibilnih osoba koje se odnose na dob osoba, fleksibilne osobe su definirane prema uzoru na rad Bezeredi i sur. (2019).

nezaposlene i neaktivne osobe (u daljnjem tekstu će se zvati samo nezaposlene i neaktivne osobe), dok se cijeli uzorak fleksibilnih osoba koristi za predviđanje plaća neaktivnih i nezaposlenih osoba Heckmanovim selekcijskim modelom.

U svrhu analiziranja empirijskih pokazatelja isplativosti rada prema odabranim tipovima kućanstava, fleksibilne osobe će se dodatno podijeliti na dvije skupine fleksibilnih jedinica: (1) fleksibilni parovi - oba člana su fleksibilna i (2) fleksibilni pojedinci. Fleksibilni pojedinci se dodatno dijele na sljedeće podskupine: (2a) fleksibilne osobe s nefleksibilnim supružnikom; (2b) fleksibilni samci u višečlanim kućanstvima; (2c) fleksibilni samci u jednočlanim kućanstvima i (2d) fleksibilni samohrani roditelji.

3.3.1.2. Struktura populacije na temelju anketnih podataka u Republici Hrvatskoj

Podaci za ADS se prikupljaju na panelnom uzorku slučajno izabranih privatnih kućanstava (DZS, 2017). Prikupljeni uzorak se ponderira na način da se svakoj osobi iz uzorka dodjeljuje odgovarajući ponder, čime se uzorak projicira na cjelokupnu populaciju. Prema podacima iz prikupljenog ADS-a za 2016., pokazalo se da u Hrvatskoj postoji 2,6 milijuna žena u dobi od 18 do 60 i muškaraca u dobi 18 do 65 godina, od čega je 1,8 milijuna, odnosno 68%, fleksibilnih osoba, a ostale osobe su nefleksibilne (tablica 3.1.). Nadalje, 1,3 milijuna fleksibilnih osoba je zaposleno, a 439 tisuća fleksibilnih osoba je nezaposleno ili neaktivno.

Tablica 3.1. Fleksibilne i nefleksibilne osobe u Hrvatskoj

	Broj osoba u populaciji	Udio u ukupnoj populaciji žena u dobi 18-60 i muškaraca u dobi 18-65 (%)
Ukupni broj žena u dobi 18-60 i muškarci u dobi 18-65	2.620.640	-
Nefleksibilne osobe	837.753	32,0
Fleksibilne osobe	1.783.067	68,0
Fleksibilne zaposlene osobe	1.343.644	51,2
Fleksibilne nezaposlene ili neaktivne osobe	439.422	16,8

Izvor: Autorovi izračuni

Što se tiče podjele fleksibilnih osoba prema spolu, tablica 3.2. prikazuje kako prema ADS-u u Hrvatskoj postoji 876 tisuća fleksibilnih žena, od čega ih je 71% zaposleno, a 29% ih je nezaposleno ili neaktivno. Fleksibilnih muškaraca je nešto više, 907 tisuća, od čega ih je 79,5% zaposleno, a 20,5% ih je nezaposleno (tablica 3.3.).

Analizira li se podjela fleksibilnih osoba prema tipovima obitelji, iz tablica 3.4. i 3.5. je vidljivo kako postoji ukupno 454 tisuće fleksibilnih parova i 874 tisuće fleksibilnih pojedinaca. Što se tiče strukture fleksibilnih parova, postoji 63,7% parova u kojima oba supružnika rade, u 29,7%

slučajeva radi samo jedan odrasli član u paru, dok u 6,6% parova niti jedan supružnik ne radi (tablica 3.4.).

Promatrajući fleksibilne pojedince (tablica 3.5.), najviše je onih koji žive u višečlanim kućanstvima (51,3%), a slijede ih osobe s nefleksibilnim supružnikom (28,6%), samci u jednočlanim kućanstvima (16,5%), te samohrani roditelji (3,6%). Dodatno, u ukupnom broju fleksibilnih pojedinaca, neaktivno ili nezaposleno je 13,4% samaca u višečlanim kućanstvima, 9,4% osoba s nefleksibilnim supružnikom, 4,2% samaca u jednočlanim kućanstvima i 0,9% samohranih roditelja.

Tablica 3.2. Podjela fleksibilnih žena prema statusu aktivnosti u Hrvatskoj

	Broj osoba u populaciji	Udio u ukupnom broju fleksibilnih žena (%)
Fleksibilne zaposlene žene	622.490	71,0
Fleksibilne nezaposlene ili neaktivne žene	253.993	29,0
Ukupni broj fleksibilnih žena	876.484	100,00

Izvor: Autorovi izračuni

Tablica 3.3. Podjela fleksibilnih muškaraca prema statusu aktivnosti u Hrvatskoj

	Broj osoba u populaciji	Udio u ukupnom broju fleksibilnih muškaraca (%)
Fleksibilni zaposleni muškarci	721.154	79,5
Fleksibilni nezaposleni ili neaktivni muškarci	185.429	20,5
Ukupni broj fleksibilnih muškaraca	906.583	100,00

Izvor: Autorovi izračuni

Tablica 3.4. Distribucija fleksibilnih parova prema statusu zaposlenja u Hrvatskoj

	Broj parova	Udio (%)
Nijedan supružnik ne radi	29.946	6,6
Jedan supružnik radi	135.137	29,7
Oba supružnika rade	289.256	63,7
Ukupno parovi	454.339	100,0

Izvor: Autorovi izračuni

Tablica 3.5. Distribucija fleksibilnih pojedinaca prema statusu zaposlenja u Hrvatskoj

	Ukupno	Ukupno (%)	Zaposleni	Zaposleni (%)	Nezaposleni ili neaktivni	Nezaposleni ili neaktivni, (u %)
Osobe s nefleksibilnim supružnikom	250.234	28,6	168.107	19,2	82.127	9,4
Samci u višečlanim kućanstvima	448.958	51,3	331.638	37,9	117.320	13,4
Samci u jednočlanim kućanstvima	143.882	16,5	106.946	12,2	36.936	4,2
Samohrani roditelji	31.316	3,6	23.305	2,7	8.010	0,9
Ukupno pojedinci	874.389	100,0	629.996	72,0	244.393	28,0

Izvor: Autorovi izračuni

Dakle, u smislu istraživanja pokazatelja isplativosti rada u Hrvatskoj, promatra se 439 tisuća nezaposlenih ili neaktivnih osoba, što ukupno čini 17% svih žena (u dobi 18-60) i muškaraca (u dobi 18-65). Detaljnije, gledano prema strukturi obitelji promatra se 30 tisuća parova u kojima nitko ne radi i 135 tisuća parova u kojima jedan odrasli član radi. Što se tiče fleksibilnih pojedinaca, u svrhu analize PPS-a promatra se ukupno oko 244 tisuće pojedinaca koji ne rade; od čega ih je 82 tisuće osoba s nefleksibilnim supružnikom; 117 tisuća samaca u višečlanim kućanstvima; 37 tisuća samaca u jednočlanim kućanstvima; te 8 tisuća samohranih roditelja.

3.3.1.3. Struktura populacije na temelju anketnih podataka za Republiku Sloveniju

Svakoj osobi iz uzorka prikupljenog na temelju ankete EU-SILC 2016 su također dodijeljeni ponderi kako bi se uzorak projicirao na cjelokupnu populaciju. Prema anketi EU-SILC provedenoj u Sloveniji, pokazalo se da postoji 1,3 milijuna žena u dobi od 18 do 60 i muškaraca u dobi 18 do 65 godina. Od toga je 820 tisuća fleksibilnih osoba, a 466 tisuća ih je nefleksibilno (tablica 3.6.). Prema statusu zaposlenosti fleksibilnih osoba, 728 tisuća ih je zaposleno, a 91 tisuća ih je nezaposleno ili neaktivno.

Tablica 3.6. Fleksibilne i nefleksibilne osobe u Sloveniji

	Broj osoba u populaciji	Udio u ukupnoj populaciji žena u dobi 18-60 i muškaraca u dobi 18-65, (%)
Ukupni broj žena u dobi 18-60 i muškarci u dobi 18-65	1.285.712	-
Nefleksibilne osobe	465.945	36,2
Fleksibilne osobe	819.767	63,8
Fleksibilne zaposlene osobe	728.273	56,6
Fleksibilne nezaposlene ili neaktivne osobe	91.494	7,1

Izvor: Autorovi izračuni

Podjela fleksibilnih osoba prema spolu otkriva da u Sloveniji postoji 390 tisuća fleksibilnih žena, pri čemu ih je 85,7% zaposleno, dok ih je 14,3% nezaposleno ili neaktivno (tablica 3.7.). S druge strane, fleksibilnih muškaraca ima 429 tisuća, pri čemu ih je čak 91,7% zaposlenih, dok ih je 8,3% nezaposlenih ili neaktivnih (tablica 3.8.).

Tablica 3.7. Podjela fleksibilnih žena prema statusu aktivnosti u Sloveniji

	Broj osoba u populaciji	Udio u ukupnom broju fleksibilnih žena (%)
Fleksibilne zaposlene žene	334.520	85,7
Fleksibilne nezaposlene ili neaktivne žene	55.953	14,3
Ukupni broj fleksibilnih žena	390.473	100,00

Izvor: Autorovi izračuni

Tablica 3.8. Podjela fleksibilnih muškaraca prema statusu aktivnosti u Sloveniji

	Broj osoba u populaciji	Udio u ukupnom broju fleksibilnih muškaraca (%)
Fleksibilni zaposleni muškarci	393.753	91,7
Fleksibilni nezaposleni ili neaktivni muškarci	35.541	8,3
Ukupni broj fleksibilnih muškaraca	429.294	100,00

Izvor: Autorovi izračuni

Nadalje, u Sloveniji postoji 219 tisuće fleksibilnih parova i 381 tisuće fleksibilnih pojedinaca (tablice 3.9. i 3.10.). Promatraju li se samo fleksibilni parovi, tablica 3.9. ilustrira kako u 84,7% fleksibilnih parova rade oba supružnika, jedan supružnik radi u 14,1% slučajeva, dok postoji tek oko 1,2% fleksibilnih parova u kojima niti jedan supružnik ne radi.

Tablica 3.9. Distribucija fleksibilnih parova prema statusu zaposlenja u Sloveniji

	Broj parova	Udio (%)
Nijedan supružnik ne radi	2.593	1,2
Jedan supružnik radi	30.938	14,1
Oba supružnika rade	185.566	84,7
Ukupno parovi	219.096	100,00

Izvor: Autorovi izračuni

U Sloveniji je ukupno 381 tisuća fleksibilnih pojedinaca (tablica 3.10.), od kojih 31,9% su osobe koje žive s nefleksibilnim supružnikom, 30,4% su samci u višečlanim kućanstvima, a 30,1% je samaca u jednočlanim kućanstvima, dok ih 7,6% otpada na samohrane roditelje. Dodatno, u ukupnom broju fleksibilnih pojedinaca, 5,1% njih su samci u višečlanim kućanstvima izvan rada, 4,8% su osobe s nefleksibilnim supružnikom izvan rada, a 3,5% su samci u jednočlanim kućanstvima izvan rada te 1,1% njih su samohrani roditelji.

Tablica 3.10. Distribucija fleksibilnih pojedinaca prema statusu zaposlenja u Sloveniji

	Ukupno	Ukupno (%)	Zaposleni	Zaposleni (%)	Nezaposleni ili neaktivni	Nezaposleni ili neaktivni, (u %)
Osobe s nefleksibilnim supružnikom	121.779	31,9	103.592	27,2	18.187	4,8
Samci u višečlanim kućanstvima	115.963	30,4	96.404	25,3	19.558	5,1
Samci u jednočlanim kućanstvima	114.860	30,1	101.369	26,6	13.490	3,5
Samohrani roditelji	28.879	7,6	24.781	6,5	4.099	1,1
Ukupno pojedinci	381.480	100,0	326.146	85,5	55.335	14,5

Izvor: Autorovi izračuni

Sumarno, u Sloveniji se u smislu istraživanja pokazatelja isplativosti rada promatra 91 tisuća nezaposlenih ili neaktivnih osoba što ukupno čini 7,1% svih žena u dobi 18-60 i muškaraca u dobi 18-65. Od toga je 36,1 tisuća osoba koje žive u fleksibilnim parovima i oko 55 tisuća fleksibilnih pojedinaca. U 2,5 tisuće fleksibilnih parova niti jedan supružnik ne radi, a u 31 tisuću parova jedan supružnik radi. Od fleksibilnih pojedinaca, analizira se 18 tisuća osoba s nefleksibilnim supružnikom, 19,5 tisuća samaca u višečlanim kućanstvima, 13,5 tisuća samaca u jednočlanim kućanstvima, te 4 tisuće samohranih roditelja.

3.3.2. Predviđanje plaća za neaktivne i nezaposlene osobe

Kako bi bilo moguće izračunati pokazatelje PPS i NSZ, potrebno je predvidjeti bruto plaće koje bi neaktivne i nezaposlene osobe mogle zaraditi u hipotetskom stanju kada bi se zaposlile. Za obje promatrane zemlje, Hrvatsku i Sloveniju, bruto plaće se predviđaju koristeći Heckmanov selekcijski model, a kao zavisna varijabla koristi se logaritam bruto plaće po satu. Predviđanje se provodi na temelju uzorka svih fleksibilnih osoba koristeći metodu maksimalne vjerodostojnosti. Analiza se provodi, posebno za muškarce i posebno za žene, kako bi se uzele u obzir razlike između spolova, odnosno različita obilježja koja utječu na predviđanje plaće. Za Hrvatsku se u jednadžbi plaće koriste sljedeće nezavisne varijable: dob (u godinama) i kvadrat dobi; obrazovanje (u godinama); radno iskustvo (u godinama) i kvadrat te varijable; te binarna varijabla koja označava prebivalište u urbanom području. U selekcijskoj jednadžbi se uz spomenute varijable dodatno koriste i sljedeće varijable: dvije binarne varijable koja označavaju stupanj zdravstvenih tegoba koje sputavaju osobe u obavljanju standardnih aktivnosti; binarna varijabla koja označava ima li promatrana osoba supružnika ili partnera; broj djece u dobi od 0 do 6 godina i 7 do 14 godina; te tri varijable koje mjere dohodak ostalih članova kućanstva. Za Sloveniju se koristi gotovo isti skup varijabli, uz iznimku da se ne koristi varijabla koja označava prebivalište u urbanom području, budući da ne postoji u anketnim podacima za tu zemlju. Varijable su detaljnije opisane u tablici 3.11.

Tablica 3.11. Opis varijabli korištenih u Heckmanovom modelu za predviđanje plaće

Nezavisne varijable	Opis varijabli
ln(placa_ps)	Prirodni logaritam bruto plaće po satu
dob	Varijabla koja određuje broj godina ispitanika
$dob^2/100$	Kvadrirani iznos varijable dob podijeljen s 100
obrazovanje	Varijabla koja određuje broj godina provedenih u obrazovanju
iskustvo	Varijabla koja određuje broj godina provedenih u radnom odnosu
$iskustvo^2/100$	Kvadrat varijable radnog iskustva podijeljen s 100

Nezavisne varijable	Opis varijabli
urban	Binarna varijabla koja poprima vrijednost 1 ako osoba živi u urbanom području
zdrav_prbl1	Binarna varijabla koja poprima vrijednost 1 ako je osoba bila ograničena, ali ne jako, zdravstvenim tegobama u aktivnostima koje ljudi inače obavljaju
zdrav_prbl2	Binarna varijabla koja poprima vrijednost 1 ako je osoba bila jako ograničena zdravstvenim tegobama u aktivnostima koje ljudi inače obavljaju
supružnik	Binarna varijabla koja poprima vrijednost 1 ako osoba ima partnera/ supružnika
djeca00_06	Varijabla koja određuje broj djece u dobi od 0 do 6 godina
djeca07_14	Varijabla koja određuje broj djece u dobi od 7 do 14 godina
dohodak1	Ekvivalentni dohodak kućanstva koji se sastoji od dohotka ostalih članova kućanstva od: (a) zaposlenosti i samozaposlenosti; (b) dohotka od kapitala i imovine; (c) primljenih privatnih transfera. Ukupni iznos je podijeljen s 10.000, a dohodak je ekvivaliziran koristeći OECD skalu.
dohodak2	Ekvivalentni dohodak kućanstva koji se sastoji od dohotka ostalih članova kućanstva od: (a) mirovine; (b) naknade za nezaposlene, naknada za bolovanje i rodiljni i roditeljski dopust. Ukupni iznos je podijeljen s 10.000, a dohodak je ekvivaliziran koristeći OECD skalu.
dohodak3	Ekvivalentni dohodak kućanstva koji se sastoji od dohotka ostalih članova kućanstva od: (a) naknada za djecu; (b) naknada socijalne zaštite. Ukupni iznos je podijeljen s 10.000, a dohodak je ekvivaliziran koristeći OECD skalu.

Izvor: Odabir autora koristeći anketne podatke za Hrvatsku i Sloveniju

3.3.2.1. Procjena bruto plaća za neaktivne i nezaposlene osobe u Republici Hrvatskoj

U tablici 3.12. dana je deskriptivna statistika varijabli korištenih u Heckmanovom selekcijskom modelu za procjenu bruto plaća neaktivnih i nezaposlenih osoba u Hrvatskoj. Prikazane su prosječne vrijednosti (pros.vr.) i standardne devijacije (st.dev.) za zaposlene i neaktivne ili nezaposlene žene i muškarce. Zanimljivo je izdvojiti kako prosječna bruto plaća po satu žena iznosi 35 kn, dok za muškarce 42 kn. Prosječni broj godina koji su zaposlene žene i muškarci proveli u obrazovanju je 13 godina, dok je za neaktivne i nezaposlene žene i muškarce prosječni broj godina provedenih u obrazovanju 12 godina.

Tablica 3.12. Deskriptivna statistika varijabli korištenih u Heckmanovom selekcijskom modelu za Hrvatsku

	Žene (N = 3.867)				Muškarci (N = 3.906)			
	Zaposlene (N = 2.589)		Nezaposlene ili neaktivne (N = 860)		Zaposleni (N = 3.046)		Nezaposleni ili neaktivni (N = 1.278)	
	Pros.vr.	St.dev.	Pros.vr.	St.dev.	Pros.vr	St.dev.	Pros.vr.	St.dev.
placa_ps	35,458	22,038	-	-	41,648	28,479	-	-
ln(placa_ps)	3,450	0,463	-	-	3,599	0,478	-	-
dob	41,640	10,588	43,559	11,192	41,577	11,841	43,624	13,714
obrazovanje	13,242	2,594	11,506	2,067	12,788	2,200	11,819	1,917

iskustvo	17,492	10,956	8,469	10,781	18,878	11,684	12,875	12,259
urban	0,245	0,430	0,149	0,357	0,211	0,408	0,195	0,397
zdrav_prbl1	0,127	0,333	0,206	0,404	0,101	0,302	0,228	0,420
zdrav_prbl2	0,020	0,142	0,061	0,239	0,021	0,142	0,085	0,279
supružnik	0,692	0,462	0,799	0,401	0,637	0,481	0,466	0,499
djeca00_06	0,174	0,460	0,245	0,591	0,220	0,540	0,119	0,453
djeca07_14	0,325	0,625	0,372	0,728	0,307	0,706	0,165	0,525
dohodak1	0,365	0,354	0,288	0,297	0,286	0,310	0,202	0,277
dohodak2	0,060	0,101	0,065	0,105	0,055	0,089	0,065	0,101
dohodak3	0,002	0,008	0,005	0,018	0,003	0,012	0,009	0,025

Izvor: Izračun autora koristeći anketne podatke za Hrvatsku

Nakon deskriptivne analize, u tablici 3.13. dane su vrijednosti procijenjenih parametara selekcijske jednadžbe i jednadžbe plaće u Heckmanovom selekcijskom modelu. Što se tiče jednadžbe plaće, pokazalo se da i kod muškaraca i kod žena veći broj godina provedenih u obrazovanju i stanovanje u urbanom području ima statistički značajnu pozitivnu vezu s razinom bruto plaće po satu. Nadalje, za oba spola se pokazalo da porast broja godina radnog iskustva ima statistički značajnu opadajuću pozitivnu vezu s visinom bruto plaće. Za žene se dodatno pokazalo da visina bruto plaće opada s brojem godina starosti. U selekcijskoj jednadžbi za žene se pokazalo da broj provedenih godina u obrazovanju ima statistički značajnu pozitivnu vezu s vjerojatnošću zaposlenosti. Nadalje, pokazalo se da vjerojatnost zaposlenosti žena pada s dobi, postojanjem ograničenih i jako ograničenih zdravstvenih problema u aktivnostima koje ljudi inače obavljaju, te s brojem djece mlađe od 7 godina i brojem djece od 7 do 14 godina.

Tablica 3.13. Procjena logaritma bruto plaće po satu Heckmanovim selekcijskim modelom za Hrvatsku

	Žene	Muškarci
	Procijenjeni parametri (standardna pogreška)	Procijenjeni parametri (standardna pogreška)
Jednadžba plaće		
dob	-0,016 (0,008)*	0,004 (0,008)
dob²/100	0,005 (0,010)	-0,010 (0,009)
obrazovanje	0,094 (0,004)***	0,089 (0,004)***
iskustvo	0,043 (0,006)***	0,020 (0,005)***
iskustvo²/100	-0,059 (0,011)***	-0,019 (0,010)*
urban	0,138 (0,018)***	0,139 (0,019)***
konstanta	2,181 (0,147)***	2,211 (0,140)***
Selekcijska jednadžba		
dob	-0,007 (0,021)	-0,045 (0,021)**
dob²/100	-0,098 (0,026)***	-0,082 (0,025)***
obrazovanje	0,138 (0,013)***	0,127 (0,014)***
iskustvo	0,200 (0,008)***	0,215 (0,013)***
iskustvo²/100	-0,278 (0,017)***	-0,230 (0,027)***

	Žene	Muškarci
	Procijenjeni parametri (standardna pogreška)	Procijenjeni parametri (standardna pogreška)
urban	0,085 (0,067)	-0,053 (0,069)
zdrav_prbl1	-0,215 (0,072)***	-0,462 (0,079)***
zdrav_prbl2	-0,507 (0,142)***	-0,843 (0,132)***
supružnik	-0,009 (0,073)	0,147 (0,080)*
djeca00_06	-0,422 (0,055)***	0,160 (0,073)**
djeca07_14	-0,183 (0,044)***	0,102 (0,059)*
dohodak1	-0,060 (0,089)	0,231 (0,099)**
dohodak2	-0,361 (0,275)	-0,244 (0,302)
dohodak3	-2,226 (2,125)	-13,027 (2,167)***
konstanta	-0,773 (0,394)**	0,094 (0,401)
rho	0,453 (0,101)***	-0,338 (0,066)***
sigma	0,401 (0,009)***	0,419 (0,006)***
lambda	0,181 (0,044)***	-0,142 (0,029)***
Broj opažanja	3.867	3.906
Cenzurirana opažanja	1.278	860
Necenzurirana opažanja	2.589	3.046
log-vjerodostojnosti	-2.738	-2.963

*Signifikantnost: *p<0,1, **p<0,05, ***p<0,01*
Izvor: izračuni autora

U selekcijskoj jednadžbi za muškarce se pokazalo da postojanje supružnika, broj djece mlađe od 7 i broj djece od 7 do 14 godina, broj godina u obrazovanju, visina dohotka ostalih članova kućanstva od zaposlenosti, samozaposlenosti, kapitala i privatnih transfera imaju statistički značajnu pozitivnu vezu s vjerojatnošću zaposlenosti. S druge strane, kod muškaraca dob promatrane osobe, postojanje zdravstvenih problema, dohodak od naknada za djecu i naknada socijalne zaštite statistički značajno utječu na vjerojatnost da je osoba zaposlena. Za muškarce i žene se pokazalo da, u selekcijskoj jednadžbi kao i u jednadžbi plaće, postoji opadajuća pozitivna statistički značajna veza između radnog iskustva i vjerojatnosti zaposlenosti.

Tablica 3.14. prikazuje prosječne vrijednosti predviđenih bruto plaća po satu prema različitim podskupinama neaktivnih i nezaposlenih osoba. Uz prosječne vrijednosti bruto plaće po satu (oznaka pros.vr.), za svaku promatranu podskupinu prikazuju se i standardne devijacije (st.dev.).

Rezultati pokazuju da prosječna bruto plaća po satu za sve neaktivne i nezaposlene osobe iznosi 27,2 kn. Žene imaju dosta nižu prosječnu predviđenu bruto plaću od muškaraca: prosječna vrijednost za žene iznosi 21,8 kn, dok za muškarce iznosi 35,2 kn. Najveću vrijednost predviđene bruto plaće po satu ima podskupina osoba s višim/visokim stupnjem obrazovanja: za muškarce s višim/visokim stupnjem obrazovanja prosječna bruto plaću po satu je 55,5 kn (20 kn više od prosjeka za tu podskupinu), za žene s višim/visokim stupnjem obrazovanja ona

iznosi 37,2 kn (15 kn više od prosjeka za tu podskupinu), dok na razini svih neaktivnih i nezaposlenih osoba s višim/visokim stupnjem obrazovanja ona iznosi 45,2 kn (18 kn više od prosjeka za tu podskupinu). Nadalje, višu predviđenu bruto plaću po satu od prosjeka ima i podskupina osoba koja živi u urbanim područjima: za muškarce u ubranim područjima je 7 kn viša od prosjeka za tu podskupinu, kod žena je veća za 5 kn veća od prosjeka, dok je za podskupinu koju čine sve neaktivne i nezaposlene osobe u urbanim područjima veća za 7 kn od prosjeka za tu podskupinu. Za muškarce vrijednost predviđene bruto plaće raste s brojem godina, tako predviđena bruto plaća po satu za osobe u dobi 51-65 iznosi 37,2 kn, a za osobe u dobi 18-30 je 33,3 kn. Međutim, valja naglasiti kako predviđene bruto plaće prema dobi ne odstupaju od prosjeka svih neaktivnih i nezaposlenih osoba za više od 2 kn. Za žene se pokazalo da promatrajući vrijednosti bruto plaće prema dobnim skupinama, najvišu vrijednost imaju neaktivne i nezaposlene žene u dobi od 18 do 30 godina, ali također niti jedna dobna podskupina ne odstupa od prosjeka svih neaktivnih i nezaposlenih osoba za više od 2 kn.

Tablica 3.14. Distribucija predviđenih plaća za neaktivne i nezaposlene osobe u Hrvatskoj (u kn)

	Žene i muškarci		Žene		Muškarci	
	Pros.vr.	St.dev.	Pros.vr.	St.dev.	Pros.vr.	St.dev.
Ukupno	27,2	10,3	21,8	7,6	35,2	8,5
Dob						
18-30	28,5	8,0	23,9	5,8	33,3	7,0
31-50	26,0	9,4	21,7	7,2	34,2	7,8
51-65	28,0	12,1	20,9	8,6	37,2	9,6
Obrazovanje						
Osnovno	15,7	6,6	11,8	3,6	23,3	4,0
Srednje	26,1	8,4	21,0	5,9	33,8	5,4
Više/visoko	45,2	12,0	37,2	7,5	55,5	8,2
Gustoća naseljenosti						
Ruralna područja	24,9	9,1	20,2	6,6	32,8	6,9
Srednje naseljena područja	27,5	8,3	22,4	7,1	34,7	6,8
Urbana područja	34,1	12,7	26,9	9,5	42,2	10,8

Izvor: izračuni autora

3.3.2.2. Procjena bruto plaća za neaktivne i nezaposlene osobe u Republici Sloveniji

U tablici 3.15. je dana deskriptivna statistika varijabli koje se koriste u Heckamnovom selekcijskom modelu za Sloveniju. Pokazalo se kako prosječna vrijednost bruto plaće po satu za muškarce iznosi 10,4 eura, dok za žene iznosi 9,2 eura. Što se tiče obrazovanja, zaposlene žene su u prosjeku 14 godina provele u obrazovanju, dok su zaposleni muškarci proveli 13 godina. Neaktivne i nezaposlene osobe su provele nešto manje godina u obrazovanju, prosjek za žene i muškarce je 12 godina.

Tablica 3.15. Deskriptivna statistika varijabli korištenih u Heckmanovom selekcijskom modelu za Sloveniju

	Žene (N = 5.219)				Muškarci (N = 4.991)			
	Zaposlene (N = 4.268)		Nezaposlene ili neaktivne (N = 419)		Zaposleni (N = 4.800)		Nezaposleni ili neaktivni (N = 723)	
	Pros.vr.	St.dev.	Pros.vr.	St.dev.	Pros.vr	St.dev.	Pros.vr.	St.dev.
placa_ps	9,239	5,409	-	-	10,387	7,270	-	-
ln(placa_ps)	2,081	0,558	-	-	2,197	0,514	-	-
dob	43,315	9,227	42,903	11,311	41,959	10,662	43,499	12,992
obrazovanje	14,597	3,146	12,253	3,430	13,866	2,874	12,475	3,009
iskustvo	19,599	11,128	14,333	14,073	18,348	11,130	21,085	14,182
zdrav_prbl1	0,073	0,261	0,065	0,247	0,059	0,235	0,112	0,316
zdrav_prbl2	0,017	0,131	0,035	0,183	0,013	0,113	0,048	0,213
supružnik	0,767	0,423	0,728	0,446	0,688	0,463	0,504	0,501
djeca00_06	0,211	0,515	0,184	0,497	0,248	0,569	0,076	0,351
djeca07_14	0,325	0,627	0,252	0,609	0,278	0,600	0,112	0,390
dohodak1	0,091	0,086	0,077	0,070	0,079	0,079	0,066	0,077
dohodak2	0,014	0,022	0,017	0,023	0,017	0,024	0,020	0,026
dohodak3	0,002	0,004	0,007	0,011	0,000	0,003	0,005	0,011

Izvor: Izračun autora koristeći anketne podatke za Sloveniju

Procjena Heckmanovog selekcijskog modela za Sloveniju prikazana je u tablici 3.16. Procijenjeni parametri u jednadžbi plaće pokazuju da broj godina provedenih u obrazovanju ima statistički značajnu pozitivnu vezu s visinom bruto plaće muškaraca i žena, dok radno iskustvo ima pozitivnu opadajuću vezu. U selekcijskoj jednadžbi se dodatno pokazalo da vjerojatnost zaposlenosti muškaraca i žena statistički značajno opada s postojanjem zdravstvenih problema, visinom dohotka ostalih članova kućanstva od mirovine i naknada za nezaposlene, dohotkom od naknada za djecu i naknada socijalne zaštite. S druge strane, dohodak ostalih članova kućanstva od zaposlenosti, samozaposlenosti, kapitala i privatnih transfera ima statistički značajnu pozitivnu vezu s vjerojatnošću zaposlenosti muškaraca i žena. Postojanje djece mlađe od 14 godina povećava vjerojatnost zaposlenosti žena, dok za muškarce samo broj djece mlađe od 7 godina povećava vjerojatnost zaposlenosti. Dodatno, kod žena se pokazalo da vjerojatnost zapošljavanja žena statistički značajno opada s postojanjem supružnika, dok za muškarce vjerojatnost zapošljavanja raste s postojanjem supruge.

Tablica 3.16. Procjena logaritma bruto plaće po satu Heckmanovim selekcijskim modelom za Sloveniju

	Žene	Muškarci
	Procijenjeni parametri (standardna pogreška)	Procijenjeni parametri (standardna pogreška)
Jednadžba plaće		
dob	0,000 (0,011)	-0,004 (0,008)
$dob^2/100$	0,016 (0,014)	0,007 (0,009)
obrazovanje	0,065 (0,003)***	0,072 (0,002)***

iskustvo	0,008 (0,004)**	0,027 (0,003)***
iskustvo^2/100	-0,025 (0,011)**	-0,052 (0,010)***
konstanta	0,840 (0,204)***	0,999 (0,139)***
Selekcijska jednadžba		
dob	0,076 (0,024)***	0,114 (0,025)***
dob^2/100	-0,100 (0,030)***	-0,126 (0,029)***
obrazovanje	0,075 (0,007)***	0,045 (0,010)***
iskustvo	0,080 (0,008)***	0,017 (0,011)
iskustvo^2/100	-0,155 (0,023)***	-0,091 (0,024)***
zdrav_prbl1	-0,060 (0,091)	-0,268 (0,099)***
zdrav_prbl2	-0,521 (0,142)***	-0,709 (0,163)***
supružnik	-0,145 (0,059)**	0,263 (0,081)***
djeca00_06	0,230 (0,051)***	0,168 (0,081)**
djeca07_14	0,184 (0,044)***	0,104 (0,070)
dohodak1	0,481 (0,278)*	0,669 (0,383)*
dohodak2	-2,824 (0,966)***	-2,473 (1,161)**
dohodak3	-56,985 (3,64)***	-54,806 (4,75)***
konstanta	-1,795 (0,453)***	-1,534 (0,457)***
rho	-0,808 (0,018)***	-0,437 (0,066)***
sigma	0,524 (0,007)***	0,457 (0,005)***
lambda	-0,423 (0.013)***	-0.200 (0,031)***
Broj opažanja	4.991	5.219
Cenzurirana opažanja	723	419
Necenzurirana opažanja	4.268	4.800
log-vjerodostojnosti	-4.463	-4.173

*Signifikantnost: *p<0,1, **p<0,05, ***p<0,01*
Izvor: izračuni autora

Tablica 3.17. analizira vrijednosti predviđenih bruto plaća po satu prema različitim podskupinama neaktivnih i nezaposlenih osoba. Prosječna bruto plaća po satu za sve neaktivne i nezaposlene osobe iznosi 8,9 eura. Muškarci imaju višu prosječnu predviđenu bruto plaću od žena: prosječna vrijednost za muškarce je 9,4 eura, dok za žene iznosi 8,7 eura. Vrijednost predviđene bruto plaće po satu raste s godinama, neaktivne i nezaposlene osobe u dobi od 50 do 65 godina imaju predviđenu bruto plaću višu od prosjeka svih neaktivnih i nezaposlenih osoba, vrijednosti za dobnu skupinu 31-50 je gotovo jednaka prosjeku, dok se vrijednosti za najmlađu dobnu skupinu od 18 do 30 godina nalaze ispod prosjeka. Nadalje, osobe s višim/visokim stupnjem obrazovanja imaju prosječnu predviđenu bruto plaću višu od prosjeka, dok su vrijednosti za neaktivne i nezaposlene osobe sa srednjim stupnjem obrazovanja manje od prosjeka. Preciznije, predviđena bruto plaća po satu za muškarce s višim/visokim stupnjem obrazovanja iznosi 12,9 eura (3,5 eura više od prosjeka za tu podskupinu), za žene s višim/visokim stupnjem obrazovanja ona iznosi 11,3 eura (2,6 eura više od prosjeka za tu

podskupinu), dok na razini svih neaktivnih i nezaposlenih osoba s višim/visokim stupnjem obrazovanja ona iznosi 11,8 eura (2,9 eura više od prosjeka za tu podskupinu).

Tablica 3.17. Distribucija predviđenih plaća za neaktivne i nezaposlene osobe u Sloveniji (u EUR)

	Žene i muškarci		Žene		Muškarci	
	Pros.vr.	St.dev.	Pros.vr.	St.dev.	Pros.vr.	St.dev.
Ukupno	8,9	2,1	8,7	2,0	9,4	2,2
Dob						
18-30	8,2	2,0	7,9	1,8	8,5	2,2
31-50	8,7	2,1	8,5	1,9	9,4	2,2
51-65	9,6	2,0	9,4	2,0	10,0	2,1
Obrazovanje						
Srednje	8,4	1,7	8,1	1,5	8,9	1,7
Više/visoko	11,8	1,9	11,3	1,7	12,9	1,9

Izvor: izračuni autora

3.3.3. Mikrosimulacijski modeli poreza i socijalnih naknada

Mikrosimulacijskim modelima poreza i socijalnih naknada simuliraju se iznosi doprinosa, poreza i socijalnih naknada na razni pojedinaca i kućanstava. U ovom radu se koriste modeli miCROmodA za Hrvatsku i slovenski modul EUROMOD-a za Sloveniju.[13] EUROMOD je mikrosimulacijski model poreza i socijalnih naknada za zemlje EU-a, a glavna prednost mu je što na temelju istog metodološkog obrasca obuhvaća sve zemlje EU-a i tako omogućuje fleksibilnost analize i komparativnu analizu rezultata (Sutherland i Figari, 2013). miCROmodA je mikrosimulacijski model hrvatskih poreza i socijalnih naknada koji se temelji na hrvatskom modulu EUROMOD-a.[14]

EUROMOD je statički mikrosimulacijski model što znači da se pretpostavlja da reforme poreza i socijalnih naknada ne utječu na ponašanje pojedinaca na tržištu rada. Dakle, na temelju reprezentativnih mikropodataka za svaku zemlju EU-a, EUROMOD omogućava komparativne izračune statičkih učinaka sustava poreza i socijalnih naknada na raspoloživi dohodak pojedinaca i kućanstava za sve zemlje EU-a kao i za EU u cjelini. Dodatno, omogućuje analizu utjecaja reformi sustava poreza i socijalnih naknada na (i) distribuciju dohotka, (iii) isplativost rada i (iii) državni proračun svake zemlje EU-a. Također, EUROMOD otkriva kako različite politike u različitim zemljama mogu pridonijeti specifičnim ili zajedničkim ciljevima zemalja kroz (i) usporedbu specifičnih instrumenata sustava poreza i socijalnih naknada među

[13] Za detaljnije informacije o modelu miCROmodA, kao i opis simuliranih politika vidjeti u radu Urban i sur. (2018b). Dodatno, više o primjenama mikrosimulacijskih modela u analizi poreza i socijalnih naknada u Hrvatskoj vidjeti u radu Urban (2016). Za detaljniji opis EUROMOD-a vidjeti rad Sutherland i Figari (2013).

[14] miCROmodA a razvijen je u okviru HRZZ projekta (UIP-09-2014-4096) koji je proveden na Institutu za javne financije.

zemljama, (ii) zamjenu određene politike ili cijelog sustava poreza i socijalnih naknada i (iii) analizu utjecaja zajedničkih promjena među zemljama (Lietz i Mantovani, 2007; Sutherland i Figari, 2013). Također, valja napomenuti kako su iznosi pojedinih instrumenata sustava poreza i socijalnih naknada koje nije bilo moguće simulirati u modelu uzeti direktno iz anketnih podataka (Jara i Tumino, 2013). Mikropodaci su za većinu zemalja preuzeti iz EU-SILC ankete, a EUROMOD omogućuje i procjene na temelju hipotetskih podataka.

miCROmodA je ustvari EUROMOD-ov „spin-off" model koji u odnosu na hrvatski modul EUROMOD-a dodatno omogućuje simuliranje poreza i socijalnih naknada na regionalnoj i lokalnoj razini u Hrvatskoj. [15] Za ulazni skup mikropodataka miCROmodA koristi podatke iz ADS-a koji su detaljniji od EU-SILC podataka za Hrvatsku koji se pak koriste u hrvatskom modulu EUROMOD-a, što je dodatna prednost korištenja miCROmod-a za Hrvatsku u odnosu na EUROMOD. S druge strane, slovenski modul EUROMOD-a koristi podatke iz EU-SILC ankete za Sloveniju.[16] U oba spomenuta mikrosimulacijska modela ugrađena su pravila iz hrvatskog i slovenskog sustava poreza i socijalnih naknada koja su vrijedila na dan 30. lipnja 2017. Dohodovne varijable iz anketa (ADS 2016 i EU-SILC 2016 za Sloveniju) se odnose na stanje u 2015., te su dodatno prilagođene na razinu iz 2017. korištenjem koeficijenata prilagodbe zasnovanih na službenoj statistici.

[15] Detaljniji opis hrvatskog modula EUROMOD-a zajedno s opisom simuliranih politika vidjeti u radu Urban i sur. (2018a)

[16] Detaljniji opis slovenskog modula EUROMOD-a zajedno s opisom simuliranih politika vidjeti u radu Kump i sur. (2018.).

4. ISPLATIVOST RADA U REPUBLICI HRVATSKOJ I REPUBLICI SLOVENIJI

U ovom poglavlju daje se kratki opis sustava poreza i socijalnih naknada u Republici Hrvatskoj i Republici Sloveniji, te se analizira utjecaj sustava poreza i socijalnih naknada na isplativost rada. Kako bi se što bolje ilustriralo koji tipovi obitelji imaju najveći problem s isplativošću rada (visokim participacijskim poreznim stopama) prvo se analiziraju hipotetska kućanstva. Potom se koristeći anketne podatke analizira stvarno stanje u Hrvatskoj i Sloveniji, odnosno otkriva se imaju li promatrane zemlje „problem" s visokim participacijskom poreznom stopom. Prvo se analizira stanje na području isplativosti rada u Hrvatskoj, zatim se ponavlja identična analiza za Sloveniju. Na kraju poglavlja je dana komparativna analiza isplativosti rada u obje zemlje. U analizi se prati stanje sustava poreza i socijalnih naknada koje je vrijedilo u 2017., odnosno na dan 30. lipnja 2017.

4.1. Opis sustava poreza i socijalnih naknada u Republici Hrvatskoj

U Hrvatskoj postoji veliki broj naknada socijalne zaštite (Šućur i sur., 2016), a najznačajnije su naknada za nezaposlene osobe, zajamčena minimalna naknada, naknada za troškove stanovanja i doplatak za djecu. Naknadu za nezaposlene primaju nezaposlene osobe u određenom vremenskom razdoblju nakon prestanka radnog odnosa. Za osobe izvan rada također postoji zajamčena minimalna naknada koju primaju osobe ili kućanstva s niskim primanjima, odnosno s primanjima nedovoljnim za ispunjavanje osnovnih životnih potreba. Dodatno, primatelji zajamčene minimalne naknade imaju pravo na naknadu za troškove stanovanja. Obitelji s djecom i niskim primanjima mogu primati doplatak za djecu.

Naknadu za nezaposlene primaju osobe koje nisu svojevoljno napustile radno mjesto, nego je to bila posljedica ugovora na neodređeno ili odluka poslodavca.[17] Vremensko razdoblje primanja naknade kreće se od 90 dana za minimalne uvjete (ako je osoba u posljednje dvije godine radila najmanje 9 mjeseci) do 450 dana uz uvjet da je osoba provela na radu više od 25 godina (tablica 4.1.). Ako osoba za vrijeme primanja naknade promijeni status na tržištu rada naknada se automatski prestaje primati.

[17] Više o zakonu kojim se definira naknada za nezaposlene u 2017. vidjeti u Narodnim novinama broj NN 16/2017 (Zakonu o posredovanju pri zapošljavanju i pravima za vrijeme nezaposlenosti).

Tablica 4.1. Trajanje prava na naknadu za nezaposlene u Hrvatskoj, 2017.

Mjeseci provedeni na prethodnom poslu	Vremensko trajanje primanja naknade u mjesecima
9 do 24	3
25 do 36	4
37 do 48	5
49 do 60	6
61 do 72	7
73 do 84	8
85 do 96	9
97 do 108	10
109 do 120	11
121 do 180	12
181 do 240	13
241 do 300	14
301 do 384	15

Izvor: Urban i sur. (2018a).

Osnovicu za utvrđivanje naknade čini prosjek bruto plaće u tromjesečnom razdoblju prije okončanja radnog odnosa. Prvih 90 dana novčana naknada se prima u iznosu od 60% utvrđene osnovice, a za preostalo vrijeme korištenja (ako osoba ima pravo) njen iznos je jednak 30% osnovice. Postoje i zakonski minimalni i maksimalni iznos naknade. Naknada ne može biti niža od 50% (1.310 kn) iznosa minimalne bruto plaće, umanjene za doprinose za obvezna osiguranja. S druge strane, maksimalni iznos za prvih 90 dana korištenja ne može prelaziti 70% (3.980 kn), a u preostalom vremenu korištenja ne smije biti viši od 35% (1.980 kn) iznosa prosječne neto plaće isplaćene po zaposlenome u pravnim osobama RH u prethodnoj godini.

Nakon prestanka primanja naknade za nezaposlene, osobe koje su izvan rada i koje ispunjavaju dohodovni cenzus za tu naknadu imaju pravo na primanje ***zajamčene minimalne naknade*** (ZMN). Glavna uloga te naknade je pomoć samcima i kućanstvima s niskim primanjima u zadovoljavanju osnovnih životnih potreba. Korisnik naknade je kućanstvo (obitelj), a pravo na naknadu imaju sva kućanstva čiji je raspoloživi dohodak ispod iznosa sredstava za uzdržavanje. Visina iznosa sredstava za uzdržavanje utvrđuje se kao zbroj udjela (doprinosa) svakog člana kućanstva. Doprinos svakog člana ovisi o tipu kućanstva, odnosno o njegovim osobnim obilježjima, a iznosi su prikazani u tablici 4.2. Nadalje, u svrhu utvrđivanja visine iznosa ZMN-a u raspoloživi dohodak kućanstva ubrajaju se sve vrste oporezivog dohotka koji se uzimaju u neto iznosima, tj. nakon odbitka doprinosa iz plaće i poreza, a od socijalnih naknada uključuju se naknada za bolovanje, naknada za nezaposlene, rodiljna i roditeljska naknada te primljena alimentacija. Konačno, iznos ZMN-a dobiva se kao razlika između sredstava za uzdržavanje i raspoloživog dohotka kućanstva.

Tablica 4.2. Mjesečni iznosi sredstava za uzdržavanje po članu u Hrvatskoj, 2017.

Samačko kućanstvo	*Iznos (kn)*
Radno sposobni samac	800,00
Radno nesposobni samac	920,00
Višečlano kućanstvo	
Odrasli član (više od 18 godina)	480,00
Samohrani roditelj	800,00
Dijete	320,00
Dijete samohranog roditelja	440,00

Izvor: Urban i sur. (2018a).

Kućanstva s niskim primanjima mogu ostvariti i pravo na ***naknadu za troškove stanovanja***, čije pravo priznaju jedinice lokalne samouprave. U radu će se simulirati prava kakva postoje u Gradu Zagrebu, gdje se visina te naknade utvrđuje do iznosa polovice ZMN-a priznatog samcu, odnosno kućanstvu. U simulacijama se pretpostavlja da primatelj naknade ima pravo na puni iznos.

Doplatak za djecu primaju kućanstva s uzdržavanom djecom do određene dobne granice i ukupnim raspoloživim dohotkom po članu kućanstva u prethodnoj godini koji ne prelazi iznos 1.663 kn (50% proračunske osnovice u RH).[18] Raspoloživi dohodak kućanstva definira se slično kao i za zajamčenu minimalnu naknadu. Što se tiče dobne granice, pravo na doplatak imaju djeca do navršene 15 godine života, odnosno do kraja školske godine u kojoj dijete navršava 15 godina. Doplatak za djecu može se i dalje primati ako dijete nastavi školovanje u srednjoj školi, ali najdulje do završetka školske godine u kojoj dijete navršava 19 godina. Iznimno, ako dijete pohađa srednju školu s programom od 5 godina doplatak se može primati najduže do završetka školske godine u kojoj dijete navršava 20 godina, dok je za djecu s oštećenim zdravljem taj prag 21 godina. Iznosi doplatka za djecu su prikazani u tablici 4.3., a oni mogu biti dodatno uvećani: (a) 25% za dijete bez oba roditelja ili za dijete čija su oba roditelja nesposobna za rad i samostalan život; (b) 15% za dijete s jednim roditeljem ili za dijete čiji je jedan roditelj nesposoban za rad i samostalan život; (c) 25% za dijete s oštećenjem zdravlja. Dodatno, za kućanstva primatelje doplatka za djecu, doplatak se povećava po 500 kn za treće i četvrto uzdržavano dijete. Primjerice, obitelj bez primanja s dva roditelja sposobna za rad i četiri djeteta (bez narušenog zdravlja) ostvaruje 4 * 299,34 + 2 * 500 = 2197,36 kuna doplatka za djecu.

[18] Spomenuti prag od 1.663 kn odnosi se na pravila koja su vrijedila u 2017. i koja se primjenjuju u ovom istraživanju.

Tablica 4.3. Pragovi i iznosi dječjeg doplatka po djetetu u Hrvatskoj, 2017.

Dohodak po članu kućanstva (kn)	Iznos po djetetu (kn)
Manje od 543,14	299,34
543,14 – 1.119,53	249,45
1.119,53 – 1.663	199,56

Izvor: Urban i sur. (2018a).

Građani koji ostvaruju dohodak dužni su u pravilu plaćati doprinose za socijalna osiguranja i porez na dohodak. U ovom kratkom opisu navodi se kako se oporezuju zaposlene osobe. Svi posloprimci plaćaju ***doprinose iz plaće*** koji se u Hrvatskoj sastoji od doprinosa za mirovinsko osiguranje. Osnovica doprinosa je bruto plaća, ali postoji minimalna i maksimalna osnovica. Minimalna osnovica iznosi 38% prosječne bruto plaće, dok je maksimalni iznos jednak šest prosječnih bruto plaća iz prethodne godine za razdoblje od siječanja do kolovoza. Postoje prvi i drugi mirovinski stup u koji se uplaćuju obvezni doprinosi za mirovinsko osiguranje. Prvi stup se odnosi na mirovinsko osiguranje na temelju generacijske solidarnosti i u njega se uplaćuje 15% osnovice. Drugi stup se sastoji od individualne kapitalizirane štednje i u njega se uplaćuje 5% osnovice.[19] Stoga ukupna stopa doprinosa za obvezno mirovinsko osiguranje iznosi 20%.

Porez na dohodak plaća se na osnovicu koja je jednaka je bruto plaći umanjenoj za doprinose iz plaće, osnovni osobni odbitak i osobne odbitke za uzdržavane članove. Iznosi osobnih odbitaka prikazani su u tablici 4.4. Osnovni osobni odbitak mjesečno iznosi 3.800kn, odbitak za svakog odraslog uzdržavanog članova iznosi 1.750 kuna mjesečno, a toliki je i odbitak za prvo dijete. Odbitak raste za svako sljedeće dijete.

Tablica 4.4. Mjesečni iznosi osobnih odbitaka u Hrvatskoj, 2017.

Stavka	Iznos (kn)
Osnovni osobni odbitak	3.800
Osobni odbitci za uzdržavane članove:	
(a) svaki uzdržavani odrasli član	1.750
(b) prvo dijete	1.750
(c) drugo dijete	2.500
(d) treće dijete	3.500

Izvor: Urban i sur. (2018a).

Mjesečna osnovica dijeli se na dva porezna razreda: dio osnovice ispod 17.500 kn oporezuje se po stopi od 24%, dok stopa oporezivanja iznad navedenog praga iznosi 36%. (tablica 4.5.)

[19] Iznimno sve osobe koje su 2002. bile starije od 40 godina mogle su hoće li svoje doprinose uplaćivati u dva stupa ili će svih 20% osnovice uplaćivati u prvi stup.

Tablica 4.5. Porezni razredi u Hrvatskoj, 2017.

Mjesečna porezna osnovica (kn)	Porezna stopa (%)
Manje od 17.500	24
Iznad 17.500	36

Izvor: Urban i sur. (2018a).

Dodatno, obvezniku poreza na dohodak obračunava se i ***prirez porezu na dohodak***. Stope prireza ovise o odlukama jedinica lokalne samouprave, a kreće se od 0 do 18%. Iznos prireza računa se kao iznos poreza na dohodak pomnožen sa stopom prireza. U hipotetskim podacima se pretpostavlja da stopa prireza iznosi 12%, a to je ujedno i prosječna stopa prireza u Hrvatskoj.

4.2. Analiza hipotetskih kućanstava u Republici Hrvatskoj

Analiza PPS-a se provodi za šest tipova kućanstava opisanih u poglavlju 3.3. Na sljedećim slikama (slika 4.1. do 4.3.) dani su grafički prikazi PPS-a i raspoloživog dohotka kućanstva za šest promatranih tipova kućanstva.

Na grafičkim prikazima, na horizontalnoj osi dane su vrijednosti bruto dohotka, dok su na vertikalnoj osi dana mjerila za raspoloživi dohodak kućanstva (lijeva strana vertikalne osi) i aritmetičko mjerilo za vrijednosti PPS-a (desna strana vertikalne osi). Bruto dohodak i raspoloživi dohodak kućanstava su mjereni kao postotak prosječne bruto plaće (PBP) u 2017., koja je iznosila 8.055 kn. Minimalna bruto plaća u 2017. iznosila je 3.276 kn, što je jednako iznosu od 40% PBP-a. Za kućanstava tipa 1 do tipa 4 u kojima potencijalno može biti zaposlen samo jedan odrasli član, analizira se PPS i raspoloživi dohodak kućanstva za vrijednosti bruto dohotka koji je veći od 40% PBP-a, odnosno za vrijednosti bruto plaće veće od minimalne. Na grafovima su prikazane i vrijednosti raspoloživog dohotka u stanju kada promatrana osoba ne radi, odnosno kada bruto dohodak kućanstva iznosi nula. Za kućanstva tipa 5 i 6 pretpostavlja se da drugi odrasli član radi uz bruto plaću od 75% PBP-a, dok prvi razmatra zaposlenje uz bruto plaće veće od 40% PBP-a. Stoga se za ta kućanstva analizira PPS i raspoloživi dohodak za razine bruto dohotka kućanstva veće od 115% PBP-a. Naime, drugi odrasli član zarađuje bruto plaću od 75% PBP-a, a prvi razmatra zaposlenje uz bruto plaće veće od minimalne što u zbroju daje ukupni bruto dohodak kućanstva veći od 115% PBP-a.

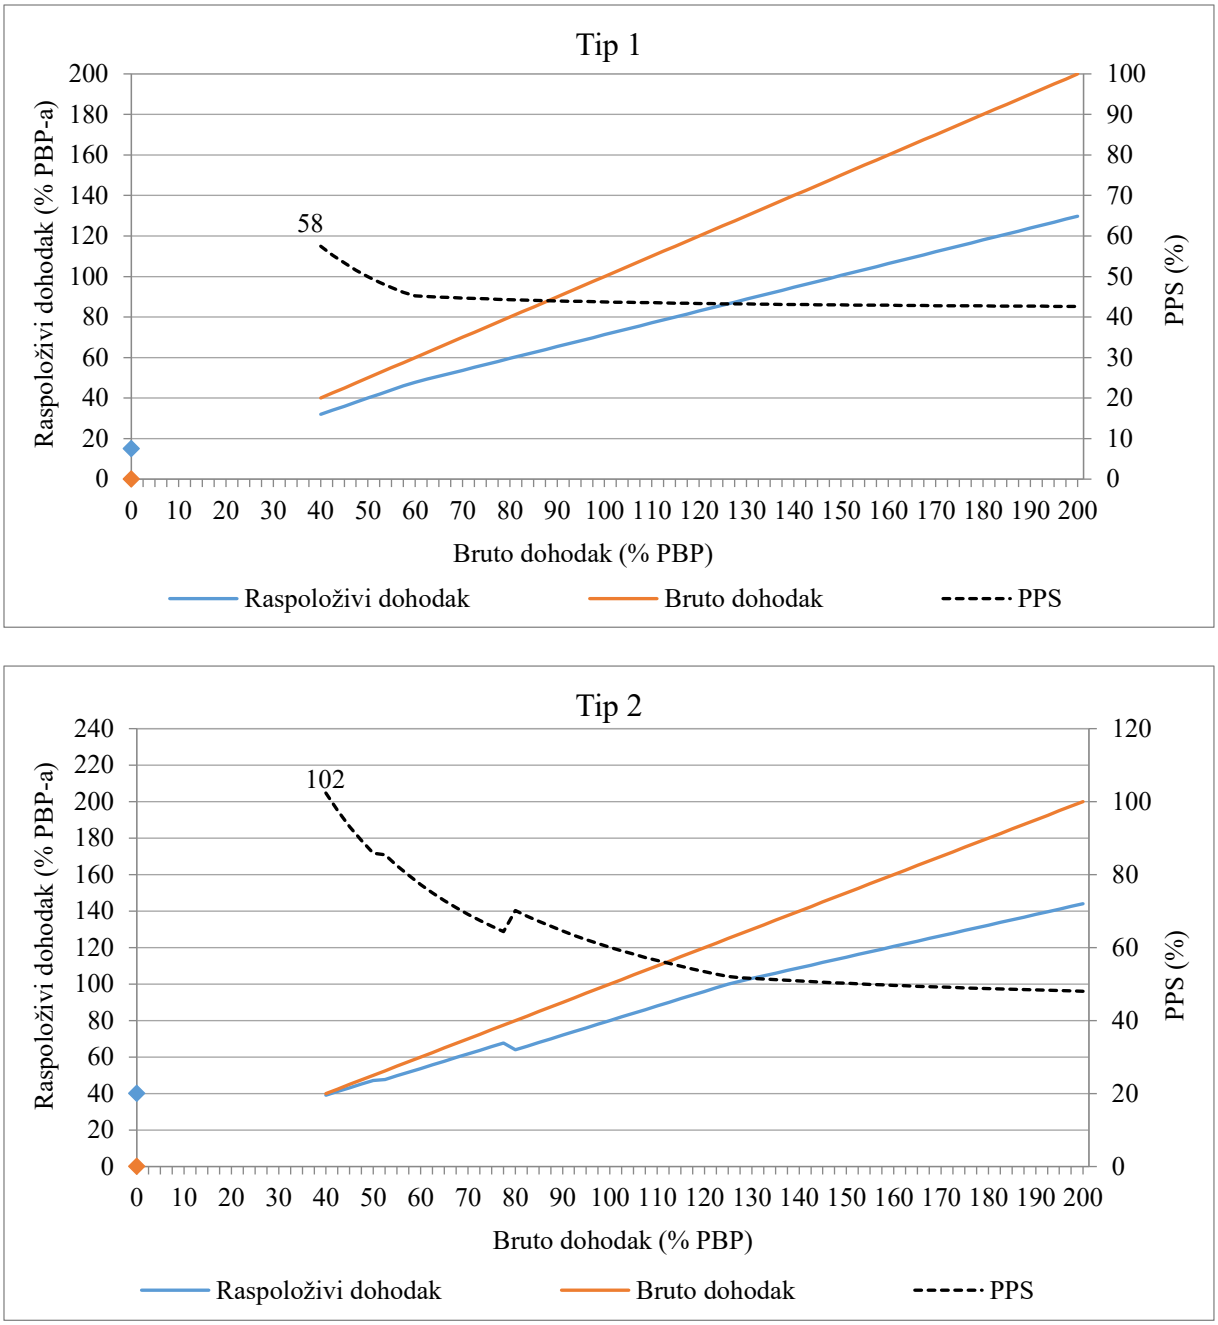
Na slici 4.1. se analiziraju PPS i raspoloživi dohodak kućanstva samaca (tip 1) koji razmatraju zaposlenje uz bruto plaće između 40% i 200% PBP-a. Raspoloživi dohodak samca koji ne radi

iznosi 15% PBP-a[20], a njegovim zapošljavanjem na minimalnu bruto plaću raspoloživi dohodak raste na 32% PBP-a. Iz toga proizlazi da PPS samca koji se zapošljava uz minimalnu bruto plaću iznosi 58%. Povećanjem vrijednosti bruto plaće na koju se samac može zaposliti smanjuje se i PPS koji uz bruto plaću od 60% PBP-a iznosi 45%. Dodatnim povećanjem potencijalne bruto plaće uz koju samci razmatraju zaposlenje, PPS neznatno pada te prilikom zapošljavanja uz bruto plaću od 200% PBP-a iznosi oko 43%.

Slika 4.1. također prikazuje kako samohrani roditelj koji ne radi i ima dvoje djece (tip 2) ostvaruje raspoloživi dohodak koji iznosi oko 40% PBP-a. Naime, takvo kućanstvo ima pravo na ZMN u iznosu od 21% PBP-a, naknadu za troškove stanovanja od 11% PBP-a, te doplatak za djecu od oko 8% PBP-a. Zaposlenjem samohranog roditelja uz minimalnu bruto plaću raspoloživi dohodak raste na 39% PBP-a, što znači da je raspoloživi dohodak promatranog kućanstva manji u slučaju zaposlenja samohranog roditelja uz minimalnu plaću nego u stanju kada on ne radi. U navedenom slučaju PPS iznosi 102% što znači da se samohranom roditelju s dvoje djece ne isplati raditi uz minimalnu plaću jer je raspoloživi dohodak čak i manji nego u stanju izvan rada. PPS postepeno pada kako se samohrani roditelj s dvoje djece može zaposliti na veće plaće, tako da uz bruto plaću od 70% PBP-a iznosi oko 70%, što je i dalje prilično visoko budući da tek 30% bruto plaće ostvarene na novom poslu ostane kućanstvu, dok se preostalih 70% gubi stoga što su se smanjili iznosi naknada koje promatrana osoba dobiva u stanju kada ne radi.[21] Visok PPS je prisutan i prilikom zaposlenja samohranog roditelja uz prosječnu bruto plaću, gdje iznosi 60%, a zapošljavanjem uz bruto plaću od 150% PBP-a PPS se smanjuje na 50%.

[20] Samac koji ne radi ostvaruje pravo na ZMN u iznosu od 10% PBP-a i naknadu za troškove stanovanja koja iznosi 5% PBP-a, što ukupno daje raspoloživi dohodak od 15% PBP-a.

[21] Zapošljavanjem samohranog roditelja s dvoje djece uz bruto plaću od 70% PBP-a kućanstvo gubi pravo na dobivanje ZMN-a i naknade za troškove stanovanja, dok se iznos doplatka za djecu smanjio i sada iznosi oko 7% PBP-a.

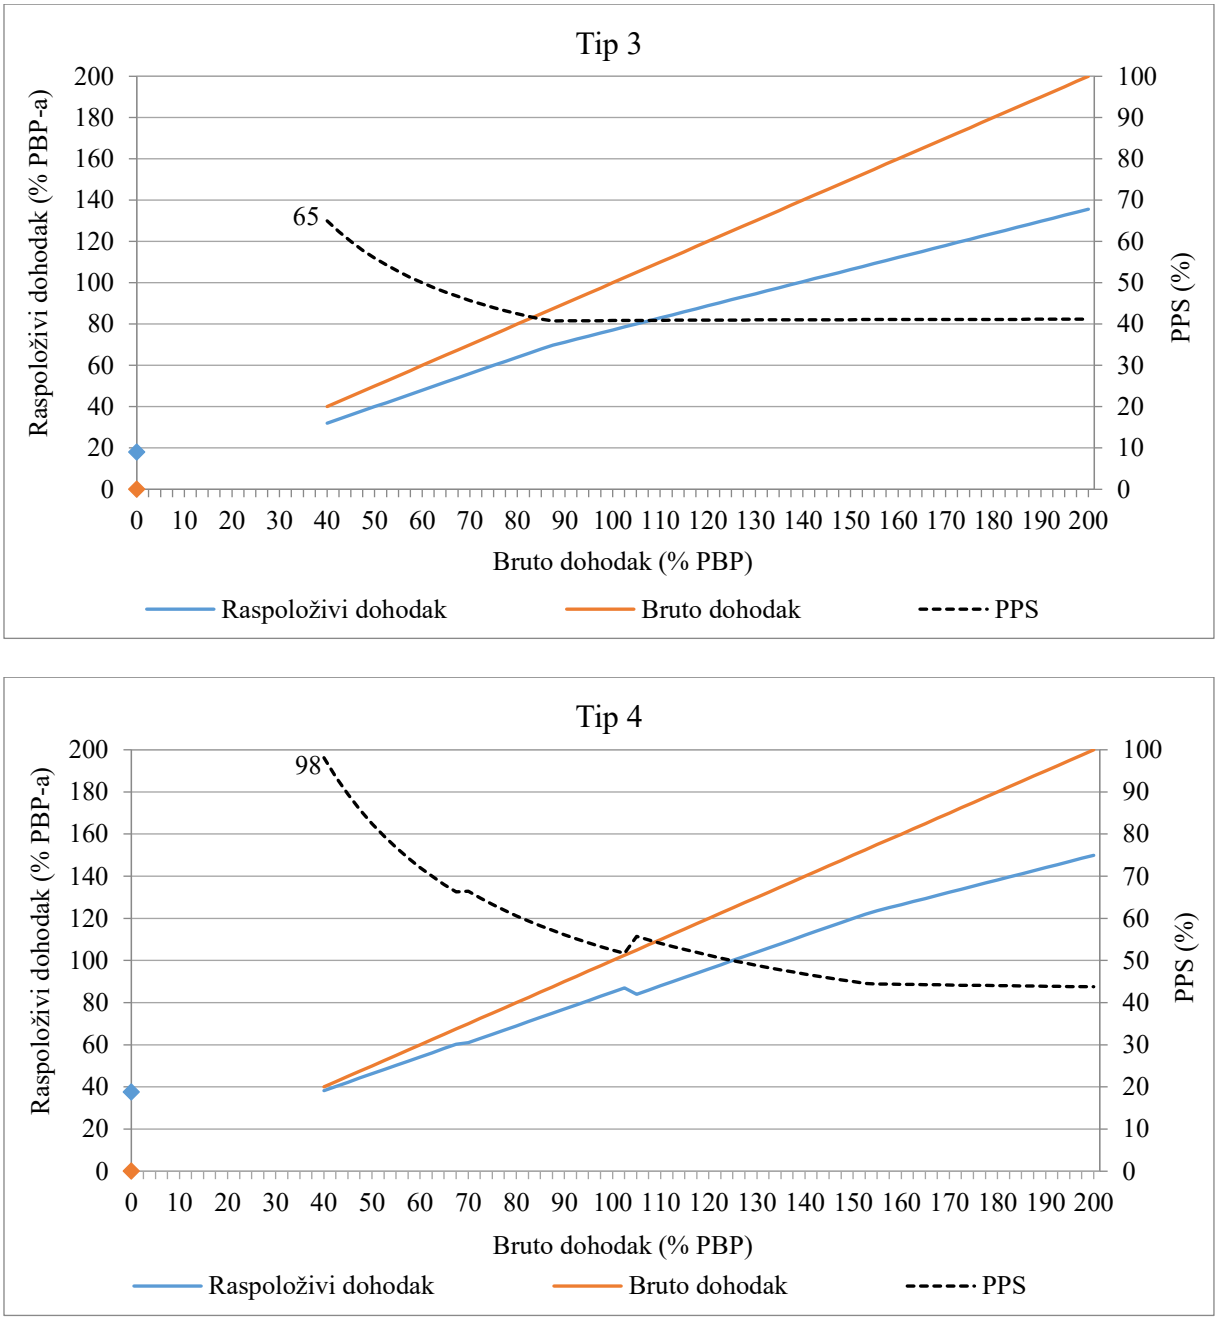


Slika 4.1. PPS i raspoloživi dohodak samaca i samohranih roditelja s dvoje djece, Hrvatska 2017.
Napomena: Na slici su izraženi iznosi PPS-a prilikom zapošljavanja uz minimalnu bruto plaću.
Izvor: Autorovi izračuni koristeći EUROMOD

Par bez djece u kojemu se prvi supružnik zapošljava uz minimalnu bruto plaću, a drugi ne radi (tip 3) ima također visok PPS, koji iznosi 65% (slika 4.2.). Naime, za takvo kućanstvo, u situaciji kada oba supružnika ne rade, raspoloživi dohodak iznosi 18% PBP-a (ZMN iznosi 12% PBP-a, a naknada za troškove stanovanja 6% PBP-a), a u situaciji kada bi se prvi član zaposlio uz minimalnu plaću raspoloživi dohodak bi iznosio 32% PBP-a. Dakle, zaposlenjem prvog supružnika raspoloživi dohodak kućanstva povećava se tek za 35% zarađene bruto plaće. Povećanje potencijalne bruto plaće uz koju se prvi supružnik može zaposliti postepeno smanjuje

PPS, koji prilikom zaposlenja na bruto plaću od 90% PBP-a iznosi 40%, nakon čega ostaje konstantan, pa PPS i uz bruto plaću od 200% PBP-a iznosi oko 40%.

Par s dvoje djece u kojemu prvi supružnik razmatra zaposlenje, a drugi ne radi (tip 4) ima veću stopu PPS-a nego takav par bez djece, a razlika je izražena pri zapošljavanju prvog supružnika uz niže vrijednosti bruto plaća (slika 4.2.).



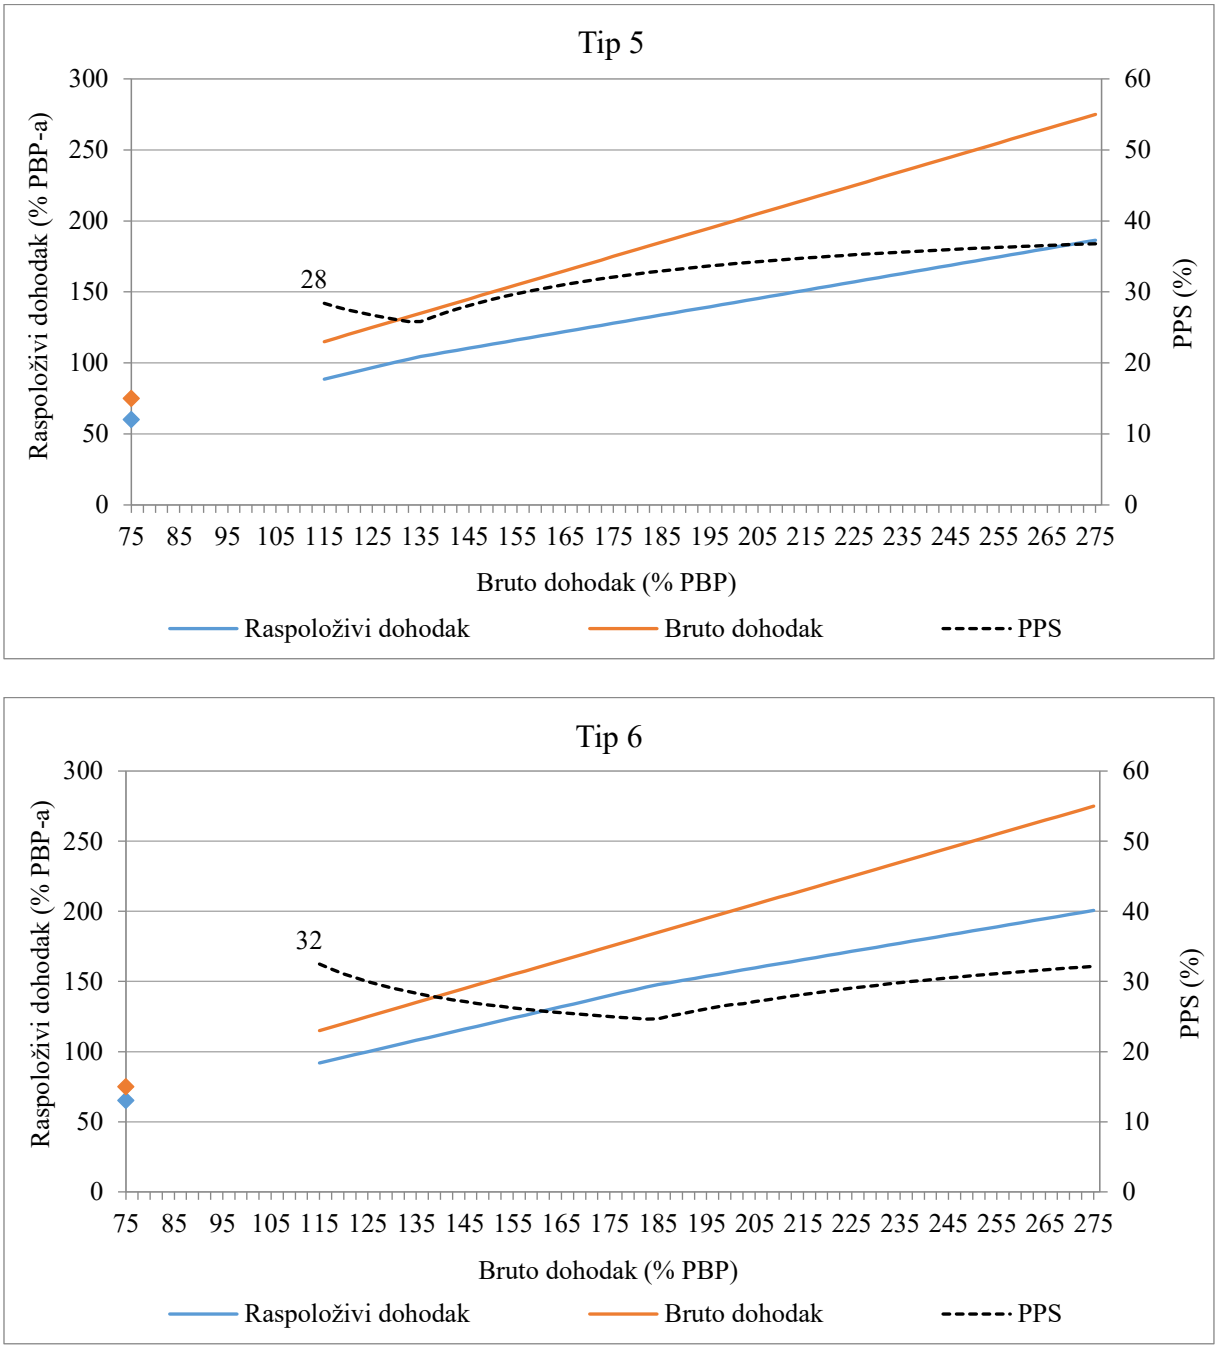
Slika 4.2. PPS i raspoloživi dohodak parova bez djece i s dvoje djece u kojima prvi supružnik razmatra zaposlenje, a drugi ne radi, Hrvatska 2017.
Napomena: Na slici su izraženi iznosi PPS-a prilikom zapošljavanja uz minimalnu bruto plaću.
Izvor: Autorovi izračuni koristeći EUROMOD

Tako par s dvoje djece u kojemu se prvi supružnik zapošljava uz minimalnu plaću, a drugi ne radi ima vrlo visok PPS, koji iznosi 98%. To znači da se zaposlenjem prvog supružnika raspoloživi dohodak kućanstva povećava tek za 2% zarađene bruto plaće, dok se preostali iznos gubi zbog smanjenja iznosa naknada. Naime, iz krivulja raspoloživog dohotka je vidljivo da kućanstvo (tip 4) u situaciji kada niti jedan supružnik ne radi ima raspoloživi dohodak koji iznosi 37% PBP-a, dok se zapošljavanjem prvog supružnika raspoloživi dohodak tek neznatno povećava i iznosi 38% PBP-a. Kada bi se prvi supružnik zaposlio uz bruto plaću od 70% PBP-a, kućanstvo bi i dalje imalo visok PPS, koji iznosi 66%, a povećanjem potencijalne bruto plaće uz koju se zapošljava prvi supružnik na 100% PBP-a, PPS bi pao na 52%. Porastom bruto plaće uz koju se zapošljava prvi supružnik na 105% PBP-a PPS je povećava za 4 postotna boda zbog činjenice da kućanstvo prestaje primati doplatak za djecu. Nakon tog iznosa bruto plaće, PPS se smanjuje i uz razinu bruto plaće od 150% PBP-a iznosi 45%.

Kućanstava u kojima već jedan supružnik radi uz bruto plaću od 75% PBP-a nemaju visok PPS prilikom zapošljavanja drugog supružnika. Tako par bez djece u kojemu se prvi supružnik zapošljava uz minimalnu bruto plaću, a drugi radi uz bruto plaću od 75% PBP-a (tip 5) ima PPS koji iznosi tek 28%. Iz slike 4.3. je vidljivo kako bi najniži PPS od 26% bio prilikom zaposlenja prvog supružnika uz bruto plaću od 50% PBP-a (tada ukupni bruto dohodak kućanstva iznosi 125% PBP-a). Na razinama potencijalne bruto plaće prvog supružnika koje su veće od 50% PBP-a, prvi supružnik počinje plaćati porez na dohodak i prirez, te se prema tome s porastom potencijalne bruto plaće povećava i PPS. Spomenuti porast PPS-a je umjeren, pa tako zapošljavanjem prvog supružnika uz bruto plaću od 100% PBP-a iznosi umjerenih 32%.

PPS parova s dvoje djece u kojima se prvi supružnik zapošljava uz minimalnu bruto plaću, a drugi već radi uz bruto plaću od 75% PBP-a (tip 6) iznosi 32% što je za oko 4 postotna boda više nego što ima takvo kućanstvo bez djece (tip 5). Razlog nešto većeg iznosa PPS-a kod kućanstva tipa 6 je postojanje djece u kućanstvu. Naime, u situaciji kada bi samo drugi supružnik radio uz bruto plaću od 75% PBP-a, takvo kućanstvo bi imalo pravo na doplatak za djecu u iznosu od 5% PBP-a. No, zaposlenjem prvog supružnika na minimalnu bruto plaću kućanstvo gubi pravo na doplatak za djecu, što rezultira nešto većim iznosom PPS-a za kućanstvo tipa 6 u odnosu na kućanstvo tipa 5. PPS za kućanstvo tipa 6 počinje postupno padati s porastom potencijalne bruto plaće uz koju bi se zaposlio prvi supružnik, a pad je prisutan do razine bruto plaće prvog supružnika od 110% PBP-a (bruto dohodak kućanstva tada iznosi 185% PBP-a), kada PPS iznosi 25%. Nakon te razine bruto dohotka, kućanstvo počinje plaćati porez na dohodak i prirez te se PPS postepeno povećava s daljnjim porastom potencijalne bruto

plaće prvog supružnika pa zapošljavanjem prvog supružnika uz bruto plaću od 200% PBP-a PPS iznosi umjerenih 32%.



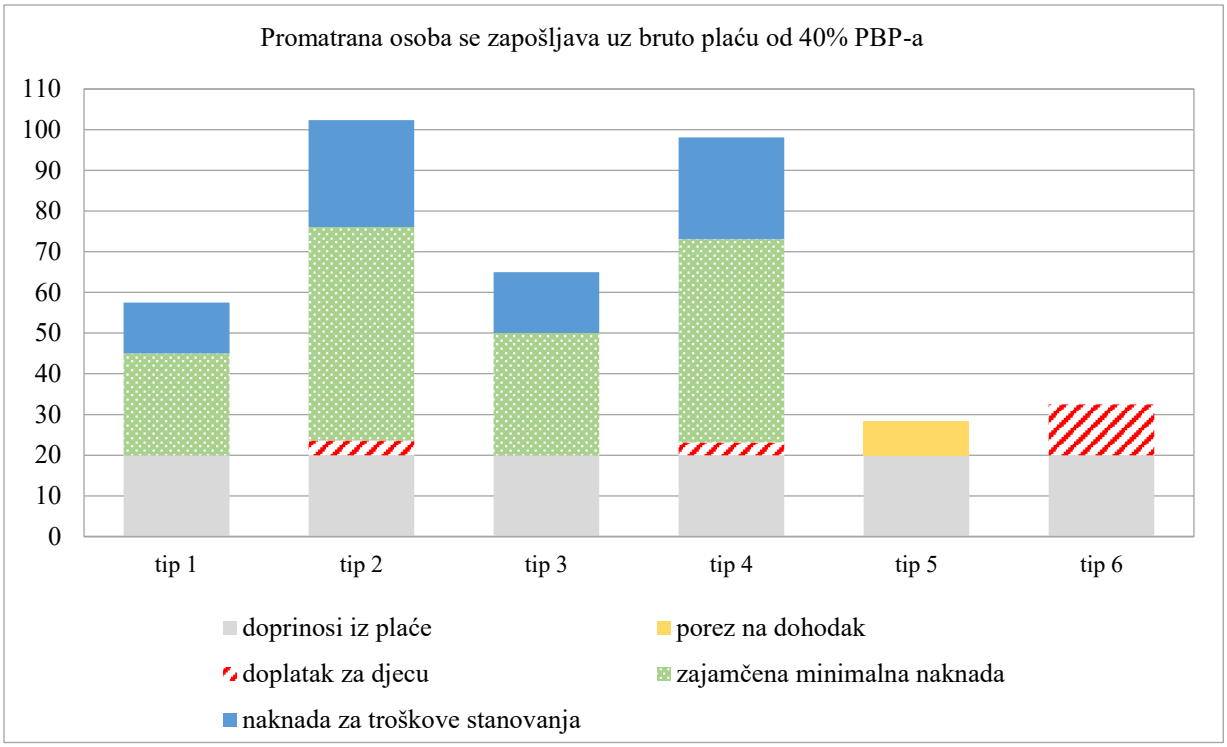
Slika 4.3. PPS i raspoloživi dohodak parova bez djece i s dvoje djece u kojima prvi supružnik razmatra zaposlenje, a drugi je već zaposlen uz bruto plaću od 75% PBP-a, Hrvatska 2017.
Napomena: Na slici su izraženi iznosi PPS-a prilikom zapošljavanja uz minimalnu bruto plaću.
Izvor: Autorovi izračuni koristeći EUROMOD

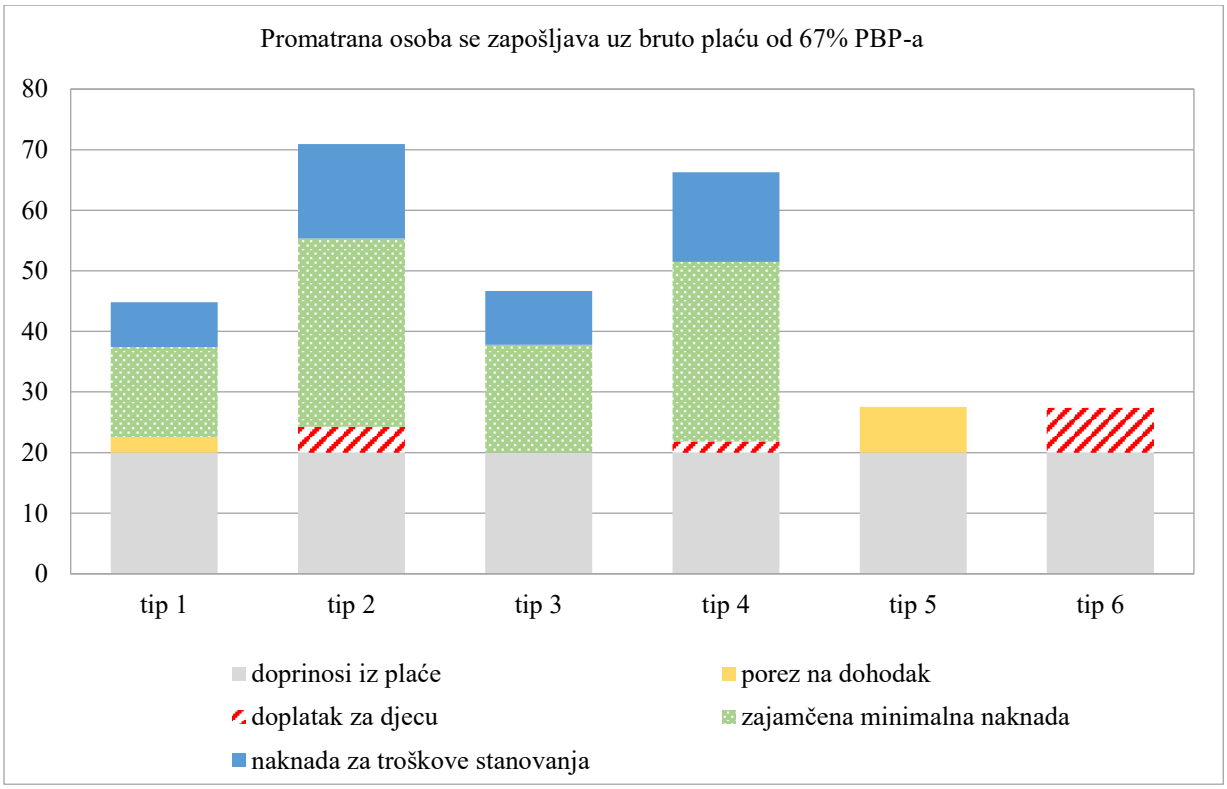
Kako bi se analizirao utjecaj pojedine komponente sustava poreza i socijalnih naknada na PPS, na slici 4.4. za svako od šest promatranih hipotetskih kućanstava analizira se dekompozicija PPS-a za odabrane visine potencijalnih bruto plaća. Za svaki tip kućanstva doprinos svake

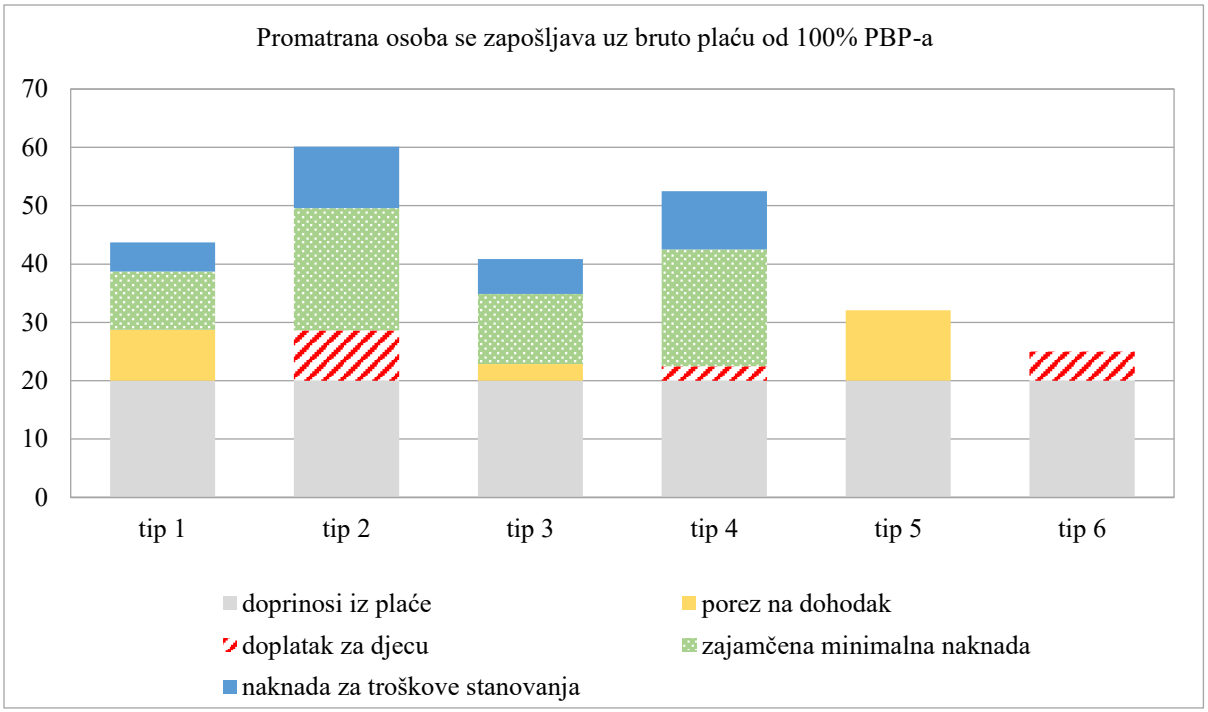
komponente je prikazan drugom bojom (vidjeti legendu ispod dijagrama), a komponente zajedno čine stupac čija je visina jednaka ukupnom PPS-u.

Vidljivo je kako doprinosi iz plaće (koji su proporcionalni porez) pridonose visini PPS-a s 20 postotnih bodova za sve tipove kućanstva i kod svih razina bruto plaća, dok se doprinos ostalih komponenti ukupnom PPS-u mijenja ovisno o visini potencijalne bruto plaće. Razmatra li se zaposlenje uz minimalnu bruto plaću, za tipove kućanstva 1 do 4 u kojima potencijalno može biti zaposlen samo jedan odrasli član, dok drugi odrasli član (ako postoji) ne radi, najveći doprinos ukupnom PPS-u daju ZMN i naknada za troškove stanovanja. Tako par s dvoje djece u kojemu se prvi supružnik zapošljava na minimalnu bruto plaću (tip 4), a drugi ne radi ima PPS od 98%, a oko 51% iznosa PPS-a je uzrokovano prestankom prava na primanje ZMN-a i 25% iznosa PPS-a je uzrokovano gubitkom naknade za troškove stanovanja. Dakle, prestanak primanja ZMN-a doprinosi ukupnom PPS-u s 50 postotnih bodova, gubitak naknade za troškove stanovanja s 25 postotnih bodova, smanjenje iznosa doplatka za djecu s 3 postotna boda, te doprinosi za mirovinsko osiguranje s 20 postotnih bodova. Kod samohranih roditelja s dvoje djece (tip 2) koji se zapošljavaju uz minimalnu bruto plaću, gubitak ZMN-a doprinosi ukupnom PPS-u s 53 postotnih bodova, prestanak primanja naknade za troškove stanovanja s 26 postotnih bodova, smanjenje iznosa doplatka za djecu 3 postotna boda, te doprinosi iz plaće 20 postotnih bodova što daje ukupni PPS od 102%. Kućanstva tipa 1 i tipa 3 u trenutku kada u njima nitko ne radi imaju pravo na manje iznose socijalnih naknada nego kućanstva tipa 2 i tipa 4, pa je u situaciji zaposlenja jednog odraslog člana doprinos socijalnih naknada ukupnoj visini PPS-a, iako i dalje prevladavajući, manji nego kod tipova 2 i 4. Dakle, od ukupne visine PPS-a od 65% za par bez djece u kojemu se prvi odrasli član zapošljava uz minimalnu bruto plaću, a druge ne radi, 30 postotnih bodova je rezultat gubitka ZMN-a, a 15 postotnih bodova nastaje zbog prestanka primanja naknade za troškove stanovanja, a 20 postotnih bodova se odnosi na doprinose iz plaće. Nadalje, za samca koje se zapošljava uz minimalnu bruto plaću (tip 1) ukupni PPS iznosi 57,5%, a 25 postotnih nastaje zbog gubitka ZMN-a, a 12,5 postotnih bodova zbog prestanka primanja naknade za troškove stanovanja.

Što se tiče tipova kućanstava 5 i 6 u kojima se prvi supružnik zapošljava uz minimalnu bruto plaću, a drugi već radi uz bruto plaću od 75% PBP-a, uz doprinose iz plaće, jedina komponenta koja daje doprinos PPS-u kod tipa 5 je porez na dohodak i prirez (8 postotnih bodova), dok je kod tipa 6 to doplatak za djecu pridonosi ukupnom PPS-u s 12,5 postotnih bodova.


Promatrana osoba se zapošljava uz bruto plaću od 40% PBP-a
110
100
90
80
70
60
50
40
30
20
10
0
tip 1
tip 2
tip 3
tip 4
tip 5
tip 6
doprinosi iz plaće
porez na dohodak
doplatak za djecu
zajamčena minimalna naknada
naknada za troškove stanovanja


Promatrana osoba se zapošljava uz bruto plaću od 67% PBP-a
80
70
60
50
40
30
20
10
0
tip 1
tip 2
tip 3
tip 4
tip 5
tip 6
doprinosi iz plaće
porez na dohodak
doplatak za djecu
zajamčena minimalna naknada
naknada za troškove stanovanja



Slika 4.4. Dekompozicija PPS-a u Hrvatskoj za 2017. na razinama plaća od: (a) 40% PBP-a; (b) 67% PBP-a; (c) 100% PBP-a
Izvor: Autorovi izračuni koristeći EUROMOD

Uspoređujući sva tri dijela slike 4.4. vidljivo je da se s porastom potencijalne bruto plaće uz koju bi se zaposlila promatrana osoba u kućanstvima smanjuje i doprinos socijalnih naknada ukupnom PPS-u što znači da su na gubitak pojedine socijalne naknade najosjetljivije osobe koje se zapošljavanju na niže razine bruto plaće. S druge strane, doprinos poreza na dohodak i prireza ukupnom PPS-u raste s povećanjem potencijalne bruto plaće. Tako naprimjer doprinos ZMN-a i naknada za troškove stanovanja ukupnom PPS-u iznosi 37 postotnih bodova za samce koji se zapošljavaju uz minimalnu bruto plaću, 22 postotnih bodova za samce koje zapošljavaju uz bruto plaću od 67% PBP-a, te 15 postotnih bodova za samce koji se zapošljavaju uz prosječnu bruto plaću. S druge strane, samci koji se zapošljavaju uz minimalnu bruto plaću ne plaćaju porez na dohodak, dok doprinosi poreza na dohodak i prireza za samce koji se zapošljavaju uz bruto plaću od 67% i 100% PBP-a redom iznose 3 i 9 postotnih bodova. Iz navedenog proizlazi kako su socijalne naknade puno više utječu na ukupni iznos PPS-a, nego porez na dohodak i prirez.

4.3. Empirijska analiza isplativosti rada u Republici Hrvatskoj

U ovom dijelu se na temelju anketnih podataka analizira kretanje PPS-a u Hrvatskoj. Prvo se analizira distribucija PPS-a neaktivnih i nezaposlenih osoba prema određenim demografskim, socio-ekonomskim i regionalnim obilježjima. Analizira se 439 tisuća nezaposlenih i neaktivnih osoba koje čini 17% radno sposobne populacije (žena u dobi 18-60 i muškaraca u

dobi 18-65). Metodologija izračuna PPS-a opisana je u dijelu 3.1., dok su anketni podaci opisani u dijelu 3.3.

Tablica 4.6. pokazuje da prosječni PPS za osobe izvan rada u Hrvatskoj iznosi 31,2%, pri čemu 6,2% promatranih osoba ima PPS između 50 i 70%, a 2,8% osoba ima PPS iznad 70%. Time se potvrđuje hipoteza **H1**, koja govori da je PPS u Hrvatskoj umjerene veličine sa značajnim postotkom osoba s visokim i vrlo visokim PPS-om.[22]

Što se tiče distribucije PPS-a prema dobi, pokazuje se da prosječni PPS za osobe mlađe dobi (18-30 godina) iznosi 27,1%, što je za oko 4 postotnih bodova manje od prosjeka za sve neaktivne i nezaposlene osobe. S druge strane, osobe srednje (31-50 godina) i starije (51-65 godina) dobi imaju nešto veći PPS od prosjeka za neaktivne i nezaposlene osobe, koji redom iznosi 32,4% i 31,9%. Također, osobe srednje i starije dobi imaju veći udio osoba s vrlo visokim PPS-om nego osobe mlađe dobi. Preciznije, 3,5% osoba srednje dobi, 2,4% starije i tek 0,8% mlađe dobi imaju vrlo visok PPS. Neaktivnih i nezaposlenih osoba srednje dobi je ujedno i najviše, oko 208 tisuća, a 131 tisuća ih je starije i 100 tisuća ih je mlađe dobi. Nadalje, pokazuje se da muške osobe imaju veći PPS od žena; PPS za muškarce iznosi 32,1%, a za žene 30,3%. Međutim, žene imaju duplo veći udio osoba s vrlo visokim PPS-om - njih 3.2%, dok 1,6% muškaraca ima vrlo visok PPS. Dodatno, postoji i više neaktivnih i nezaposlenih žena nego muškaraca, oko 255 tisuća žena naprama 184 tisuća muškaraca.

Osobe s osnovnim stupnjem obrazovanja imaju puno veći PPS (43,9%) od osoba s srednjim (30,7%) i višim/visokim (29,6%) stupnjem obrazovanja. Također, 14,0% osoba s osnovnim stupnjem obrazovanja ima vrlo visok PPS, dok taj udio opada s stupnjem obrazovanja, pa 2,3% osoba s srednjim i 1,0% osoba s višim/visokim stupnjem obrazovanja ima vrlo visok PPS. Međutim, osoba s osnovnim stupnjem obrazovanja ima najmanje, 14 tisuća, dok ih je 390 tisuća sa srednjim i 35 tisuća s višim/visokim obrazovanjem. PPS se gotovo ne mijenja s mjestom stanovanja, pa PPS osoba koje žive u urbanim i ruralnim područjima redom iznosi 31,4% i 31,2% što je oko prosječne vrijednosti za cijelu neaktivnu i nezaposlenu populaciju, a PPS osoba iz srednje naseljenih područja je tek nešto niži i iznosi 30,5%.

[22] Kako je spomenuto i u prvom poglavlju, u literaturi se PPS ispod 50% smatra umjerenim, između 50 i 70% smatra se visokim, dok se PPS veći ili jednak 70% smatra vrlo visokim.

Tablica 4.6. Distribucija PPS-a prema određenim demografskim karakteristikama u Hrvatskoj (u %)

	Broj neaktivnih i nezaposlenih osoba (u tis.)	Prosječni PPS	Distribucija populacije prema razredima PPS-a			
			< 30 %	[30%, 50%>	[50%, 70%>	≥ 70%
Ukupno	439	31,2	62,3	28,7	6,2	2,8
Dob						
18-30	100	27,1	75,0	20,7	3,5	0,8
31-50	208	32,4	59,6	28,5	8,4	3,5
51-65	131	31,9	57,0	35,7	5,0	2,4
Spol						
Muško	184	32,1	56,9	33,4	8,1	1,6
Žensko	255	30,3	66,2	25,6	5,0	3,2
Obrazovanje						
Osnovno	14	43,9	21,2	52,4	12,4	14,0
Srednje	390	30,7	64,7	26,5	6,6	2,3
Više/visoko	35	29,6	52,0	46,5	0,5	1,0
Gustoća naseljenosti						
Ruralna područja	227	31,2	64,0	26,4	6,5	3,2
Srednje naseljena područja	120	30,5	62,6	28,3	7,4	1,8
Urbana područja	92	31,4	57,8	35,8	4,4	2,0
Broj djece						
Nema djece	259	29,8	63,0	30,6	5,4	1,1
Jedno dijete	79	30,7	69,8	20,8	5,5	4,0
Dva djeteta	56	31,1	66,0	23,4	7,0	3,7
Troje ili više djece	45	38,8	41,3	39,5	12,0	7,2
Tržišni dohodak ostalih članova kućanstva (u tis. kn)						
0 do 0,5	55	45,7	23,8	38,3	29,4	8,6
0,5 do 2,5	63	31,2	65,6	25,0	4,8	4,6
2,5 do 5	87	27,8	77,6	16,1	4,6	1,7
5 do 10	130	27,4	74,5	22,9	2,4	0,3
više od 10	104	30,6	52,5	44,5	1,3	1,8

Izvor: Autorovi izračuni koristeći EUROMOD

Rezultati pokazuju da s brojem maloljetne djece u kućanstvima raste i PPS, pa PPS osoba koje nemaju djece iznosi 29,8%, dok je PPS osoba s troje ili više djece 38,8%. Također, puno veći udio osoba s troje ili više djece ima vrlo visok PPS, njih 7,2%, za razliku od osoba bez djece kojih tek 1,1% ima vrlo visok PPS. Što se tiče broja takvih osoba, 259 tisuće neaktivnih i nezaposlenih osoba nema djece, a 45 tisuća ih ima troje ili više djece.

PPS se razlikuje i prema visini tržišnog dohotka ostalih članova kućanstva. Tako osobe čiji članovi kućanstva ostvaruju tržišni dohodak manji od 500 kn imaju najveći PPS, koji iznosi 45,7%, a 8,6% takvih osoba ima vrlo visok PPS. S druge strane, najmanji PPS u iznosu od 27,4% imaju osobe čiji članovi kućanstva ostvaruju tržišni dohodak između 5 i 10 tisuća kuna, a 0,3% takvih osoba ima vrlo visok PPS. Osobe čiji članovi kućanstva ostvaruju tržišni

dohodak veći od 10 tisuća kuna imaju nešto viši PPS od prethodno spomenute grupe, no taj iznos je još uvijek manji od prosjeka za cjelokupni neaktivnu i nezaposlenu populaciju.

Kako bi se pokazalo koja su demografska, socio-ekonomska i geografska obilježja statistički značajno povezana s vjerojatnošću vrlo visokog PPS-a, u tablici 4.7. su prikazani procijenjeni parametri i granični utjecaji provedenog logit modela. Zavisna varijabla poprima vrijednost jedan za neaktivne i nezaposlene osobe koje imaju PPS veći ili jednak 70%, dok je za ostale osobe vrijednost nula. Granični utjecaj mjeri kako jedinična promjena odabrane nezavisne varijable utječe na vjerojatnost vrlo visokog PPS-a, uz uvjet da su sve ostale varijable konstantne, odnosno da se nalaze na svojim prosječnim vrijednostima.

Tablica 4.7. Procjena vjerojatnosti vrlo visokog PPS-a u Hrvatskoj logit modelom

	Procijenjeni parametri (standardna pogreška)	Granični utjecaj
Dob (bazna: 51-65)		
18-30	-0,591 (0,531)	-0,006
31-50	0,345 (0,332)	0,003
Spol (bazna: muško)		
Žensko	1,091 (0,311)***	0,010
Obrazovanje (bazna: osnovno)		
Srednje	-1,932 (0,349)***	-0,018
Više/visoko	-2,096 (0,694)***	-0,020
Gustoća naseljenosti (bazna: ruralna i srednje naseljena područja)		
Urbana područja	-0,026 (0,369)	-0,001
Broj djece (bazna: bez djece)		
Jedno dijete	1,118 (0,353)***	0,012
Dva djeteta	1,038 (0,427)**	0,011
Troje ili više djece	1,719 (0,393)***	0,026
Tržišni dohodak ostalih članova kućanstva (u tis. kn)	-0,297 (0,050)***	-0,003
Konstanta	-2,114 (0.397)***	
Broj opažanja	2,144	
Broj opažanja s vrlo visokim PPS-om	54	
Prob > chi2	0,000	
Pseudo R2	0,216	

*Signifikantnost: *p<0,1, **p<0,05, ***p<0,01*
Izvor: izračuni autora

Rezultati pokazuju da je spol osobe statistički značajno povezan s vjerojatnošću vrlo visokog PPS-a; uz ostale varijable konstantne žene u prosjeku imaju za 1 postotni bod veću vjerojatnost vrlo visokog PPS-a nego muškarci. Za osobe s osnovnim stupnjem obrazovanja se pokazuje da imaju statistički značajnu veću vjerojatnost vrlo visokog PPS-a nego osobe s srednjim i višim/visokim obrazovanjem. Točnije, uz ostale varijable konstantne, osobe sa srednjim i višim/visokim stupnjem obrazovanjem imaju u prosjeku za 1,8, odnosno 2,0

postotnih bodova nižu vjerojatnost vrlo visokog PPS-a od osoba s osnovnim stupnjem obrazovanja. Broj djece se pokazao statistički značajno povezan s vjerojatnošću vrlo visokog PPS-a, za osobe s djecom je više vjerojatnije da će imati vrlo visok PPS nego za osobe bez djece. Na primjer, za osobe s troje ili više djece je u prosjeku za 2,6 postotnih bodova vjerojatnije da će imati vrlo visok PPS nego za osobe bez djece. Također, rezultati pokazuju da je vjerojatnost vrlo visokog PPS-a pada s tržišnim dohotkom ostalih članova kućanstva. Dodatno, pokazuje se da ne postoji statistički značajna veza između dobi i vrlo visokog PPS-a, te da ni gustoća naseljenosti ne utječe na vjerojatnost vrlo visokog PPS-a.

Dakle, na temelju prethodno dobivenih rezultata logit modela potvrđuje se hipoteza **H1a**, koja kaže da vjerojatnost vrlo visokog PPS-a za osobe izvan rada pada sa stupnjem njihova obrazovanja i s razinom tržišnog dohotka koji ostvaruju njihov supružnik i ostali članovi kućanstva, a raste s brojem maloljetne djece.

Nadalje, da bi se otkrilo kako različiti elementi sustava poreza i socijalnih naknada doprinose ukupnom PPS-u, u tablici 4.8. dana je dekompozicija PPS-a prema različitim podskupinama nezaposlenih i neaktivnih osoba. Stupci (1) do (6) označavaju doprinos određenih elemenata ukupnom PPS-u, a njihov zbroj je prikazan u stupcu (7) koji označava ukupni PPS. Prvo, doprinosi iz plaće (stupac 1) imaju jednak doprinos od 20 postotnih bodova za sve podskupine. Na razini svih neaktivnih i nezaposlenih osoba doprinos poreza na dohodak i prireza (stupac 2) iznosi 3,1 postotnih bodova, a taj element najveći doprinos ima za podskupinu s višim/visokim obrazovanjem (6,4 postotnih bodova) i osobe koje žive u urbanim područjima (4,7 postotnih bodova). Spomenute podskupine mogu ostvariti više plaće od ostalih pa progresivnost poreza na dohodak rezultira povećanim doprinosom poreza na dohodak ukupnom PPS-u.

Kako je i za očekivati, doplatak za djecu (stupac 3) ima najveći doprinos od 11 postotnih bodova ukupnom PPS-u za podskupinu osoba s troje ili više djece, dok prosječni doprinos tog elementa iznosi 2,1 postotnih bodova. Nadalje, ZMN i naknada za troškove stanovanja (stupac 4) najveći doprinos ukupnom PPS-u od 12,3 postotnih bodova imaju za podskupnu osoba s osnovnim stupnjem obrazovanja, a prosječni doprinos za skupinu neaktivnih i nezaposlenih je 3,3 postotnih bodova. Zbog niskog stupnja obrazovanja, takve osobe teže pronalaze posao pa su sklonije primanju naknada čija je svrha zadovoljavanje osnovnih životnih potreba. Prosječni doprinos naknada za nezaposlene (stupac 5) je 1,2 postotna boda, a najveći doprinos te naknade ima podskupina osoba od 51 do 65 godina. Duljina razdoblja u

kojem se prima naknada za nezaposlene ovisi o godinama provedenim na prethodnom poslu pa su starije osobe kandidati koji su na godišnjoj razini skloniji primanju većih iznosa te naknade nego mlađe osobe.

Dohodak od neformalne samozaposlenosti ili ugovora o djelu koji ostvaruju određene osobe izvan rada, a koji se gubi u stanju zaposlenosti na puno radno vrijeme također ima određeni doprinos ukupnom PPS-u. Prosječni doprinos neformalne djelatnosti ukupnom PPS-u iznosi 1,5 postotnih bodova, a od promatranih podskupina najveći doprinos spomenute komponente je prisutan kod muškaraca gdje iznosi 2,1 postotnih bodova, te za osobe srednje generacije (31-50 godina) i one koji žive u ruralnim područjima kod kojih doprinos ukupnom PPS-u iznosi 1,8 postotnih bodova.

Tablica 4.8. Dekompozicija PPS-a prema različitim podskupinama u Hrvatskoj

	DIP	PND	DPZD	SOCN	NZN	DNSZ	UK PPS
	(1)	(2)	(3)	(4)	(5)	(6)	(7)
Ukupno	20,0	3,1	2,1	3,3	1,2	1,5	31,2
Dob							
18-30	20,0	3,2	1,5	1,7	0,0	0,7	27,1
31-50	20,0	2,6	3,1	4,4	0,5	1,8	32,4
51-65	20,0	3,6	1,1	3,2	2,8	1,2	31,9
Spol							
Muško	20,0	3,6	1,1	4,0	1,3	2,1	32,1
Žensko	20,0	2,7	2,9	2,9	0,9	0,7	30,1
Obrazovanje							
Osnovno	20,0	1,6	1,6	12,3	0,3	1,4	37,3
Srednje	20,0	2,7	2,1	3,3	1,1	1,5	30,7
Više/visoko	20,0	6,4	1,7	0,4	0,2	0,9	29,6
Gustoća naseljenosti							
Ruralna područja	20,0	2,4	2,2	3,7	1,1	1,8	31,2
Srednje naseljena područja	20,0	3,0	1,9	3,7	0,9	1,0	30,5
Urbana područja	20,0	4,7	2,3	2,0	1,2	1,2	31,4
Broj djece							
Nema djece	20,0	4,1	0,0	3,0	1,3	1,4	29,8
Jedno dijete	20,0	2,3	2,4	3,8	0,4	1,8	30,7
Dva djeteta	20,0	1,6	3,8	3,5	1,0	1,2	31,1
Troje ili više djece	20,0	0,3	11,0	4,9	1,0	1,6	38,8

Kratice: DIP – doprinos iz plaće; PND – porez na dohodak i prirez; DPZD – doplatak za djecu; SOCN – zajamčena minimalna naknada i naknada za troškove stanovanja; NZN – naknada za nezaposlene; DNSZ – dohodak od neformalne samozaposlenosti ili ugovora o djelu koji primaju osobe koje ne rade, a taj dohodak se gubi prilikom zaposlenja; UK PPS – ukupni PPS.
Izvor: Autorovi izračuni koristeći EUROMOD

4.4. Opis sustava poreza i socijalnih naknada u Republici Sloveniji

Slovenija ima sveobuhvatan sustav socijalne zaštite, a kao i u Hrvatskoj, posebno se ističu naknada za nezaposlene, socijalna pomoć, subvencija najamnine i doplatak za djecu.

Naknadu za nezaposlene mogu u određenom vremenskom razdoblju primati nezaposlene nakon prestanka radnog odnosa na određeno vrijeme ili nakon prisilnog raskida radnog odnosa od strane poslodavca. Naknadu mogu primati osobe koje su u posljednje dvije godine bile zaposlene najmanje 9 mjeseci, a za osobe mlađe od 30 godina dovoljno je biti zaposlen minimalno 6 mjeseci. Naknada se može primati u razdoblju od 2 do 25 mjeseca nakon prestanka radnog odnosa, a trajanje ovisi o duljini vremenskog razdoblja provedenog na prethodnom poslu i o starosti nezaposlene osobe (tablica 4.9.). Tako najkraće vremensko razdoblje primanja naknade od dva mjeseca imaju osobe mlađe od 30 godina koje su u posljednje dvije godine bile zaposlene od 6 do 8 mjeseci, a najdulje (25 mjeseci) je primaju osobe starije od 55 godina koje su bile zaposlene više od 25 godina.

Tablica 4.9. Trajanje prava na naknadu za nezaposlene u Sloveniji, 2017.

Vrijeme provedeno na prethodnom poslu	Trajanje prava na naknadu (u mjesecima)
6 do 8 mjeseci za osobe mlađe od 30 godina	2
9 mjeseci do 5 godina	3
5 do 15 godina	6
15 do 25 godina	9
Više od 25 godina	12
Više od 25 godina za osobe od 50 do 54 godine	19
Više od 25 godina za osobe starije od 55 godina	25

Izvor: Kump i sur. (2018).

Osnovicu za utvrđivanje naknade čini prosjek bruto plaće u posljednjih osam mjeseci prije okončanja radnog odnosa, a za osobe mlađe od 30 godina uzima se prosjek za posljednjih pet mjeseci. U prva tri mjeseca se isplaćuje naknada u iznosu od 80% osnovice, za sljedećih devet mjeseci iznos je postavljen na 60% osnovice, dok za preostalo vrijeme naknada iznosi 50% utvrđene osnovice. Mjesečni iznos naknade ne smije prijeći zakonski postavljen maksimum od 890,50 eura i ne smije biti niži od 350 eura.

Osobe koje nisu u mogućnosti osigurati svoje osnovne materijalne potrebe mogu primati ***socijalnu pomoć***. Naknada se dodjeljuju na razini kućanstva/obitelji, a pravo na naknadu imaju sva kućanstva čiji je raspoloživi dohodak ispod osnovnog minimalnog dohotka. Iznos osnovnog minimalnog dohotka se utvrđuje kao zbroj udjela svakog člana kućanstva, a kako prikazuje tablica 4.10., iznosi udjela ovise o tipu kućanstva i obilježjima članova. Za zaposlene osobe postoji i dodatak čiji iznos ovisi o broju sati rada u mjesecu. Tako samac koji ne radi ili radi manje od 60 sati na mjesec ostvaruje iznos osnovnog minimalnog dohotka od 293 eura. Ako radi između 60 i 128 sati tjedno, taj iznos je 374 eura, a ako radi više od 128 sati tjedno, iznos se povećava na 456 eura. Nadalje, u svrhu izračuna iznosa naknade u raspoloživi dohodak

kućanstva ubrajaju se sve vrste oporezivog dohotka koji se uzimaju u neto iznosima, tj. nakon odbitka doprinosa iz plaće i poreza, a od socijalnih naknada uključuju se naknada za bolovanje, naknada za nezaposlene, rodiljna i roditeljska naknada te doplatak za djecu (u obzir se uzima iznos doplatka za djecu koji je umanjen za 20% iznosa doplatka koji se dodjeljuje za prvo dijete u prvom dohodovnom razredu, a također se u obzir ne uzima ni dodatak za djecu samohranih roditelja i djecu koja nisu upisana u predškolski odgoj, jednokratna potpora za novorođenče i pronatalitetni dodatak). Konačan iznos socijalne pomoći dobiva se kao razlika između osnovnog minimalnog dohotka i raspoloživog dohotka kućanstva.

Tablica 4.10. Mjesečni iznosi osnovnog minimalnog dohotka u Sloveniji, 2017.

Članovi kućanstva	Iznos (EUR)
Prvi odrasli član	293
Prvi odrasli član koji radi 60 do 128 sati na mjesec	374
Prvi odrasli član koji radi više od 128 sati na mjesec	456
Nezaposleni samac u dobi 18 do 25 godina koji živi s roditeljima	205
Svaki sljedeći odrasli član	167
Svaki sljedeći odrasli član koji radi 60 do 128 sati na mjesec	208
Svaki sljedeći odrasli član koji radi više od 128 sati na mjesec	249
Najstarije dijete u obitelji	222
Svako sljedeće dijete u obitelji	193
Dodatak za djecu samohranih roditelja	59

Izvor: Kump i sur. (2018).

Kućanstva koja žive u unajmljenim stanovima i čiji je raspoloživi dohodak ispod određenog dohodovnog praga imaju pravo na ***subvenciju najamnine***. Dohodovni prag jednak je zbroju (a) osnovnog minimalnog dohotka koji se računa za socijalnu pomoć, (b) 30% raspoloživog dohotka kućanstva i (c) procijenjene neprofitne najamnine. U svrhu izračuna subvencije najamnine u raspoloživi dohodak kućanstva ubrajaju se sve vrste oporezivog dohotka koji se uzimaju u neto iznosima, tj. nakon odbitka doprinosa iz plaće i poreza, a od socijalnih naknada uključuju se naknada za bolovanje, naknada za nezaposlene, rodiljna i roditeljska naknada, doplatak za djecu i socijalna pomoć, dok iznosi se potpore za novorođenče i pronatalitetni dodatak ne uzimaju u obzir. Iznos procijenjene neprofitne najamnine ovisi o veličini stana, a maksimalna veličina stana koja se uzima u obzir pri određivanju neprofitne najamnine ovisi o broju članova obitelji. Maksimalni iznosi procijenjene neprofitne najamnine prikazani su prema veličini stana u tablici 4.11. Konačno, ukupni iznos naknade dobiva se kao razlika između dohodovnog praga za kućanstvo i raspoloživog dohotka kućanstva. Maksimalni iznos naknade ne smije biti veći od 80% iznosa procijenjene neprofitne najamnine.

Tablica 4.11. Mjesečni iznosi procijenjene neprofitne najamnine prema strukturi kućanstva u Sloveniji, 2017.

Broj članova kućanstva	Maksimalna veličina stana (m2)	Iznos (EUR)
1	30	85
2	45	125
3	55	152
4	65	180
5	75	208
6	85	235

Izvor: Kump i sur. (2018).

Kućanstva s djecom koja imaju relativno niske iznose raspoloživog dohotka imaju pravo na ***doplatak za djecu***. Naknada se dodjeljuje ovisno o visini raspoloživog dohotka po članu kućanstva. Raspoloživi dohodak kućanstva sastoji se od svih vrsta oporezivog dohotka koji se uzimaju u neto iznosima, tj. nakon odbitka doprinosa iz plaće i poreza, a od socijalnih naknada uključuju se naknada za bolovanje, naknada za nezaposlene, rodiljna i roditeljska naknada. Iznosi doplatka za djecu dodjeljuju se prema razredima koji su podijeljeni prema raspoloživom dohotku po članu kućanstva, dobi i obrazovnoj razini djeteta, a iznosi naknade po djetetu prikazani su u tablici 4.12.

Tablica 4.12. Pragovi i iznosi dječjeg doplatka po djetetu u Sloveniji, 2017. (u EUR)

Dohodak po članu kućanstva	Iznosi po djetetu u dobi do 12 godina			Iznos po djetetu u dobi od 13 do 18 godina u srednjoj školi		
	Prvo dijete	Drugo dijete	Treće i sljedeće	Prvo dijete	Drugo dijete	Treće i sljedeće
Manji od 185,43	114	126	137	114	126	137
185,44 – 309,05	98	108	118	98	108	118
309,06 – 370,86	75	83	92	75	83	92
370,87 – 432,67	59	67	75	59	67	75
432,68 – 545,98	48	56	64	48	56	64
545,99 – 576,90	30	38	46	30	38	46
576,91 – 659,30	30	38	45	43	51	71

Izvor: Kump i sur. (2018).

Za djecu samohranih roditelja iznos doplatka se povećava za 30%, a iznosi za djecu do 6 godina koja ne pohađaju vrtić se povećavaju za 20%. Dodatno, za kućanstva primatelje doplatka za djecu dodjeljuje se i pronatalitetni dodatak, koji za treće uzdržavano dijete iznosi 395 eura, a za četiri i više uzdržavane djece iznosi 480 eura.

Osobe koje ostvaruju dohodak plaćaju doprinose iz plaće i porez na dohodak. Radi jednostavnosti opisuje se samo oporezivanje zaposlenih osoba. Zaposlenici plaćaju ***doprinos iz plaće*** koji se u Sloveniji sastoji od doprinosa za mirovinsko osiguranje, zdravstveno osiguranje, osiguranje od nezaposlenosti i doprinosa za porodiljni dopust. Ukupna stopa doprinosa iz plaće

iznosi 22,1%, a doprinos svake komponente ukupnoj stop je prikazan u tablici 4.13. Osnovica za plaćanje doprinosa je bruto plaća.

Tablica 4.13. Stope doprinosa iz plaće u Sloveniji, 2017.

Komponente doprinosa	Stopa doprinosa (%)
Mirovinsko osiguranje	15,50
Zdravstveno osiguranje	6,36
Osiguranje od nezaposlenosti	0,14
Rodiljni dopust	0,10
Ukupno	22,10

Izvor: Kump i sur. (2018).

Porez na dohodak plaća se na poreznu osnovicu koja je jednaka je bruto plaći umanjenoj za doprinose iz plaće, osnovni osobni odbitak i odbitke za uzdržavane članove. Iznosi odbitaka prikazani su u tablici 4.14.. Osnovni osobni odbitak ovisi o visini bruto plaće, a ako u kućanstvu postoje odrasle uzdržavane osobe (osobe koje ne rade) ili djeca, porezni obveznik ima pravo na dodatne odbitke za uzdržavane članove. Porezna osnovica se dijeli na pet poreznih razreda koji su prikazani u tablici 4.15.

Tablica 4.14. Godišnji iznosi osobnih odbitaka u Sloveniji, 2017. (u EUR)

Osobni odbitci za uzdržavane članove:	
(a) Osobe s bruto plaćom manjom od 11.166	6.520
(b) Osobe s bruto plaćom između 11.166 i 12. 571	4.419
(c) Osobe s bruto plaćom većom od 12. 571	3.303
Odbitci za uzdržavane članove	
(a) Odrasli uzdržavani član	2.437
(b) Prvo dijete	2.437
(c) Drugo dijete	2.649
(d) Treće dijete	4.419
(e) Četvrto dijete	6.188

Izvor: Kump i sur. (2018).

Tablica 4.15. Porezni razredi u Sloveniji, 2017.

Mjesečna porezna osnovica (EUR)	Porezna stopa (%)
Manje od 8.021	16
8.021 do 20.400	27
20.400 do 48.000	34
48.000 do 70.907	39
Iznad 70.907	50

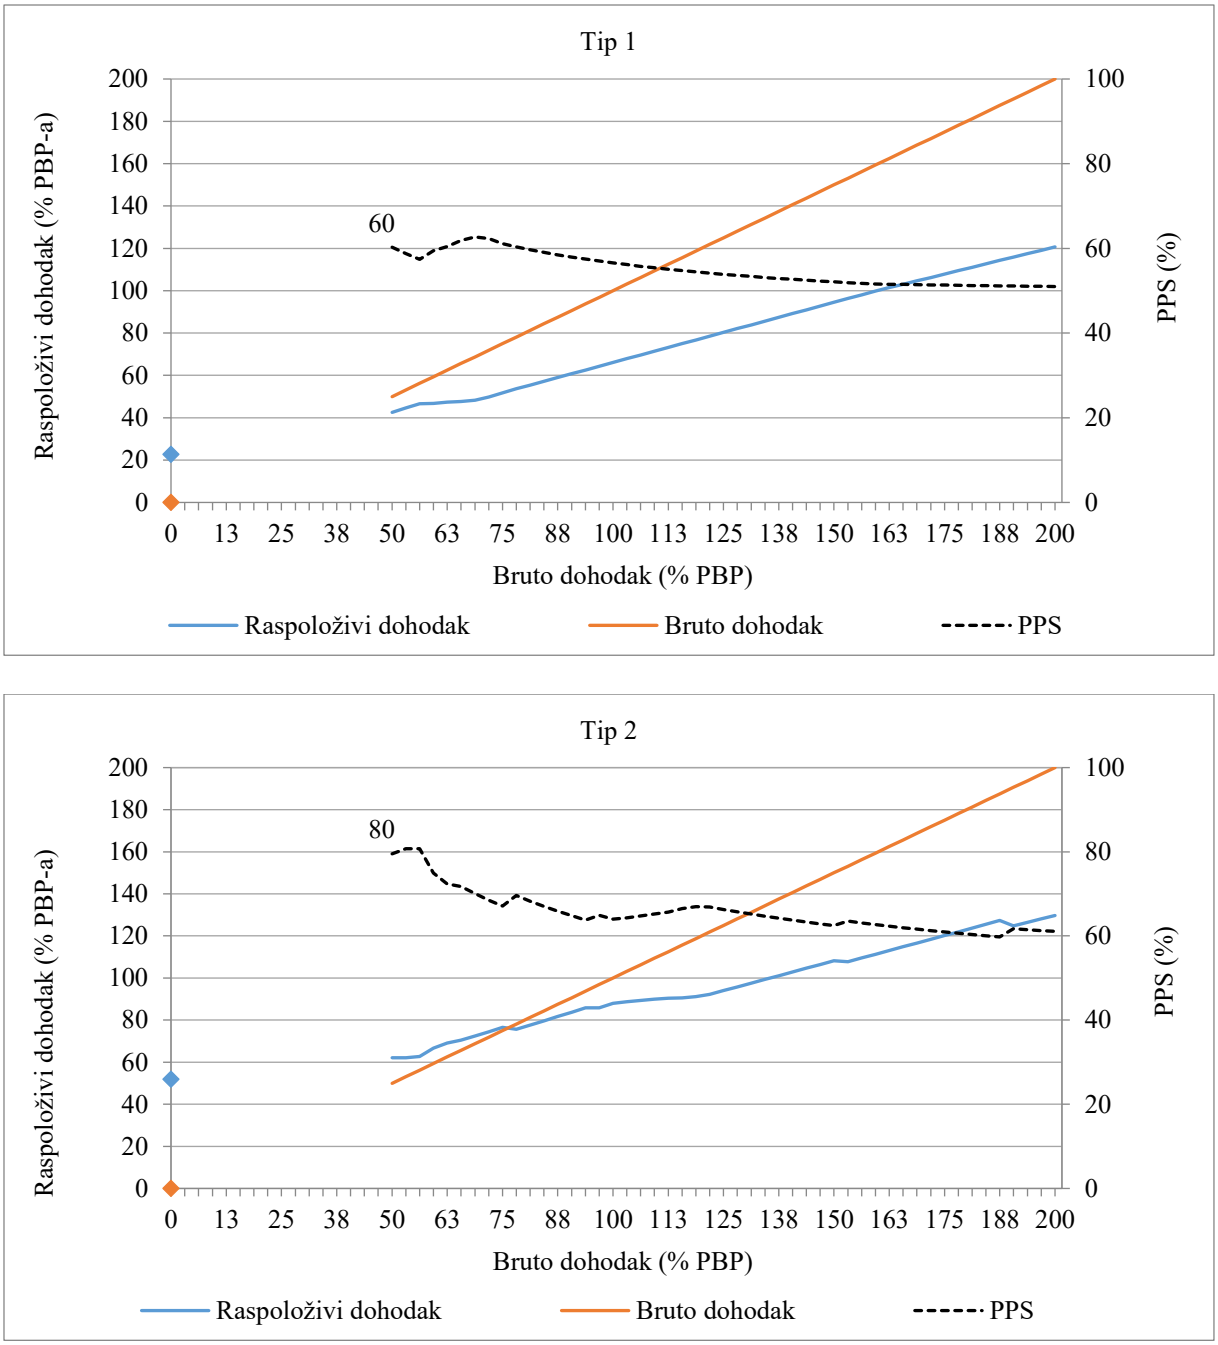
Izvor: Kump i sur. (2018).

4.5. Analiza hipotetskih kućanstava u Republici Sloveniji

Na temelju grafičkih prikaza (slike 4.5 do 4.7), u ovom dijelu se provodi analiza PPS-a za šest tipova hipotetskih kućanstava definiranih u poglavlju 3.3. Na grafičkim prikazima, na horizontalnoj osi dane su vrijednosti bruto dohotka, dok su na vertikalnoj osi dana mjerila za raspoloživi dohodak kućanstva (lijeva strana vertikalne osi) i aritmetičko mjerilo za vrijednosti PPS-a (desna strana vertikalne osi). Bruto dohodak i raspoloživi dohodak kućanstava su mjereni kao postotak prosječne bruto plaće (PBP) u 2017., koja je iznosila 1.585 eura. Minimalna bruto plaća u 2017. iznosila je 805 eura, što znači da je minimalna plaća jednaka oko 50% PBP-a. Za kućanstava tipa 1 do 4, u kojima potencijalno može biti zaposlen samo jedan odrasli član, a drugi odrasli član (koji postoji samo u tipovima 3 i 4) ne radi, analizira se PPS i raspoloživi dohodak kućanstva za vrijednosti bruto dohotka veće od 50% PBP-a, odnosno za vrijednosti bruto plaće veće od minimalne. Na slikama se dodatno prikazuju i vrijednosti raspoloživog dohotka u stanju kada promatrana osoba ne radi, odnosno kada bruto dohodak kućanstva iznosi nula. Za kućanstva tipa 5 i 6 pretpostavlja se da drugi odrasli član radi uz bruto plaću od 75% PBP-a, dok prvi razmatra zaposlenje uz bruto plaće veće od 50% PBP-a. Stoga se za ta kućanstva analizira PPS i raspoloživi dohodak za razine bruto dohotka kućanstva veće od 125% PBP-a.

Prvo se na slici 4.5. analizira PPS i raspoloživi dohodak samaca (tip 1) koji razmatraju zaposlenje uz bruto plaće između 50% i 200% PBP-a. Raspoloživi dohodak samaca koji ne rade iznosi 23% PBP-a,[23] a zapošljavanjem samca uz minimalnu bruto plaću raspoloživi dohodak iznosi 43% PBP-a. Slijedom toga PPS samca koji se zapošljava uz minimalnu bruto plaću iznosi 60%. Povećanjem vrijednosti bruto plaće uz koju se samac može zaposliti, PPS blago raste te uz bruto plaću od 70% PBP-a iznosi 63%. Nakon toga, s povećanjem bruto plaće PPS opada te prilikom zapošljavanja samca uz prosječnu bruto plaću PPS iznosi 57%, a uz bruto plaću od 200% PBP-a iznosi oko 51%.

[23] Samac koji ne radi ostvaruje pravo na socijalnu pomoć u iznosu od 18% PBP-a i naknadu za troškove stanovanja koja iznosi 5% PBP-a, što ukupno daje raspoloživi dohodak od 23% PBP-a.



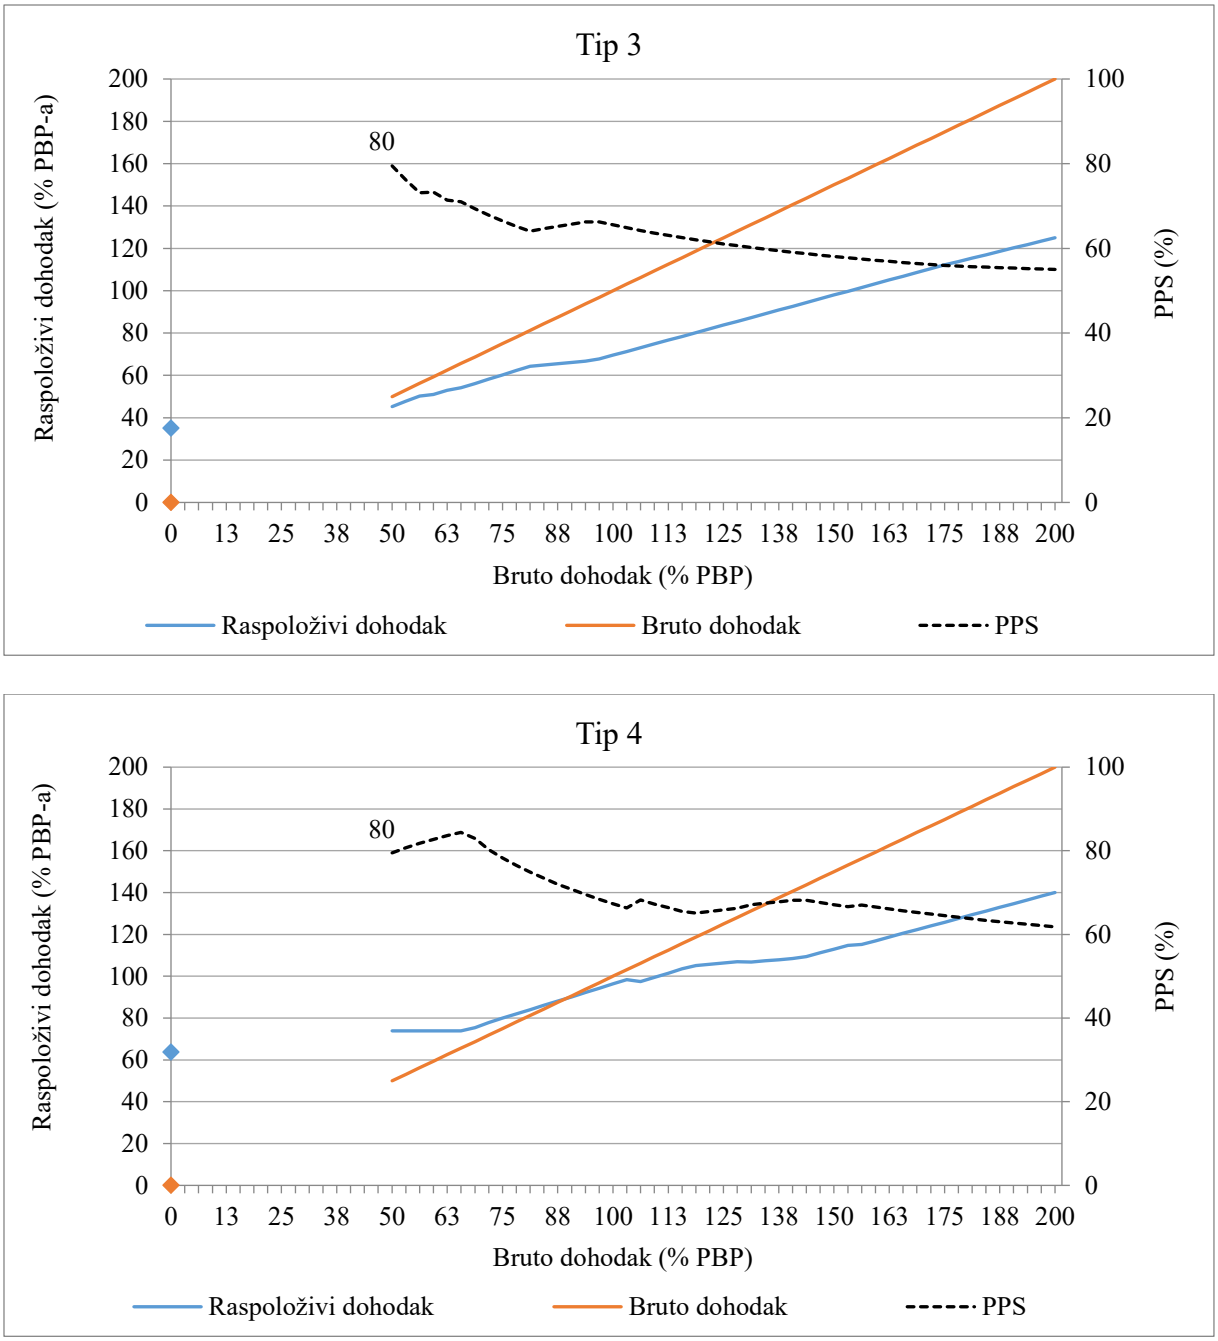
Slika 4.5. PPS i raspoloživi dohodak samaca i samohranih roditelja s dvoje djece, Slovenija 2017.
Napomena: Na slici su izraženi iznosi PPS-a prilikom zapošljavanja uz minimalnu bruto plaću.
Izvor: Autorovi izračuni koristeći EUROMOD

Drugi dio slike 4.5. prikazuje samohranog roditelja s dvoje djece (tip 2). Samohrani roditelj koji ne radi i ima dvoje djece ima pravo na socijalnu pomoć u iznosu od 29% PBP-a, naknadu za troškove stanovanja od 8% PBP-a te doplatak za djecu koji iznosi 15% PBP-a, što ukupno daje raspoloživi dohodak od 52% PBP-a. Kada bi se promatrani samohrani roditelj zaposlio uz

minimalnu bruto plaću, raspoloživi dohodak kućanstva bi iznosio 62% PBP-a,[24] što rezultira PPS-om od 80%. PPS u iznosu od 80% ukazuje na činjenicu da se zapošljavanjem samohranog roditelja raspoloživi dohodak kućanstva povećava tek za 20% iznosa zarađene bruto plaće, a preostali iznos se gubi zbog činjenice što su se zaposlenjem samohranog roditelja povećali porezi i smanjili iznosi naknada. S porastom potencijalne bruto plaće uz koju se može zaposliti promatrani samohrani roditelj, iznos PPS-a postepeno pada te uz bruto plaću od 70% PBP-a PPS iznosi 69%, a dodatnim povećanjem bruto plaće do iznosa prosječne PPS dodatno pada na iznos od 64%. Povećanje bruto plaće na iznose veće od prosječne uzrokuje tek neznatan pad PPS-a, pa uz bruto plaće od 150% i 200% PBP-a PPS redom iznosi 62% i 61%.

Na prvom dijelu slike 4.6. analizira se par bez djece u kojemu prvi supružnik razmatra zaposlenje, a drugi ne radi (tip 3). Spomenuto kućanstvo u situaciji kada niti jedan odrasli član ne radi ima pravo na socijalnu pomoć u iznosu od 29% PBP-a i na naknadu za troškove stanovanja od 6% PBP-a, pa tada ukupni raspoloživi dohodak kućanstva iznosi 35% PBP-a. Zapošljavanjem prvog supružnika uz minimalnu bruto plaću kućanstvo ostvaruju dohodak od plaće u iznosu od 39% PBP-a, naknada za troškove stanovanja ostaje ista i iznosi 6% PBP-a, no kućanstvo gubi pravo na cjelokupan iznos socijalne pomoći pa ukupni raspoloživi dohodak iznosi 45% PBP-a. Dakle, raspoloživi dohodak u stanjima kada prvi supružnik ne radi i kada radi uz minimalnu bruto plaću su gotovo jednaki što znači postoje slabi financijski poticaji za zapošljavanje prvog supružnika uz minimalnu bruto plaću. PPS je vrlo visok i iznosi 80% što ukazuje na činjenicu da se zapošljavanjem prvog supružnika raspoloživi dohodak kućanstva povećava tek za 20% iznosa zarađene bruto plaće, a preostalih 80% iznosa zarađene bruto plaće se gubi zbog činjenice da je kućanstvo izgubilo pravo na socijalnu pomoć te da je zaposleni član morao platiti doprinose iz plaće. Nadalje, povećanje potencijalne bruto plaće uz koju se prvi supružnik može zaposliti postepeno smanjuje PPS koji prilikom zaposlenja na bruto plaće od 70%, 100% i 150% PBP-a redom iznosi 69%, 66% i 58%.

[24] Samohrani roditelj s dvoje djece koji radi uz minimalnu bruto plaću ostvaruje dohodak od zaposlenja u iznosu od 38% PBP-a, 13% PBP-a iznosi doplatak za djecu, 3% PBP-a dobiva se od socijalne pomoći, te 8% PBP-a iznosi naknada za troškove stanovanja što ukupno daje raspoloživi dohodak u iznosu od 62% PBP-a.

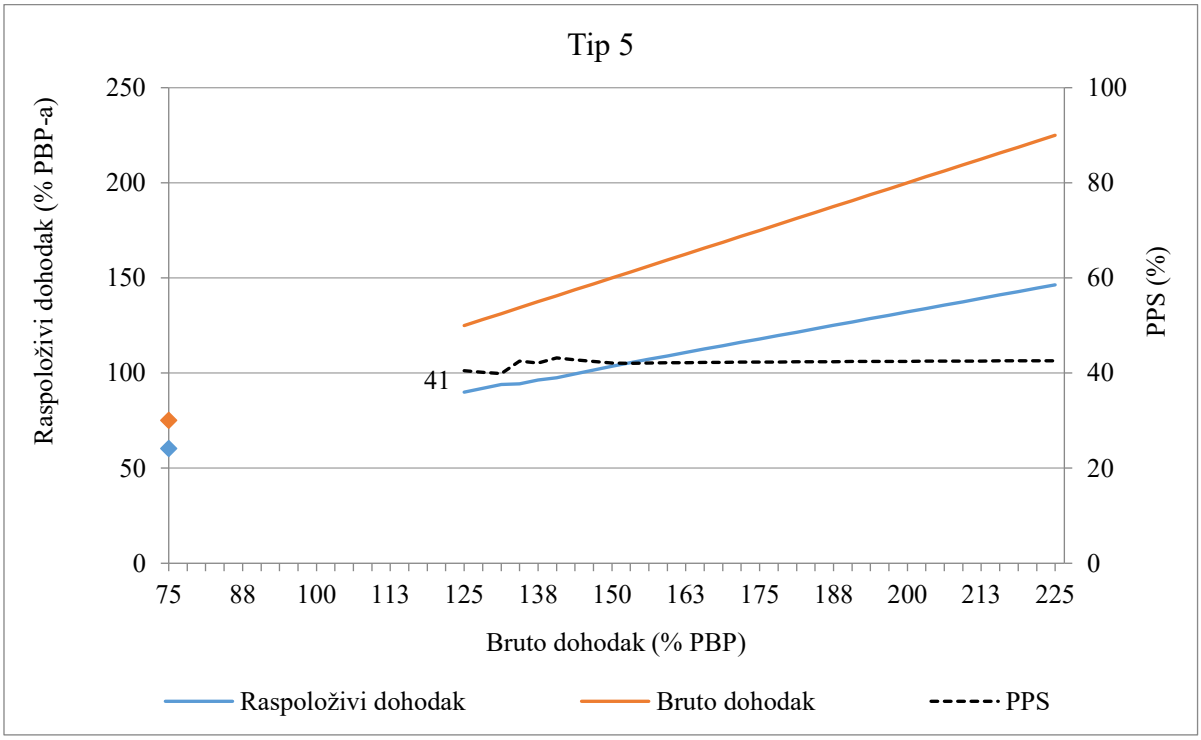


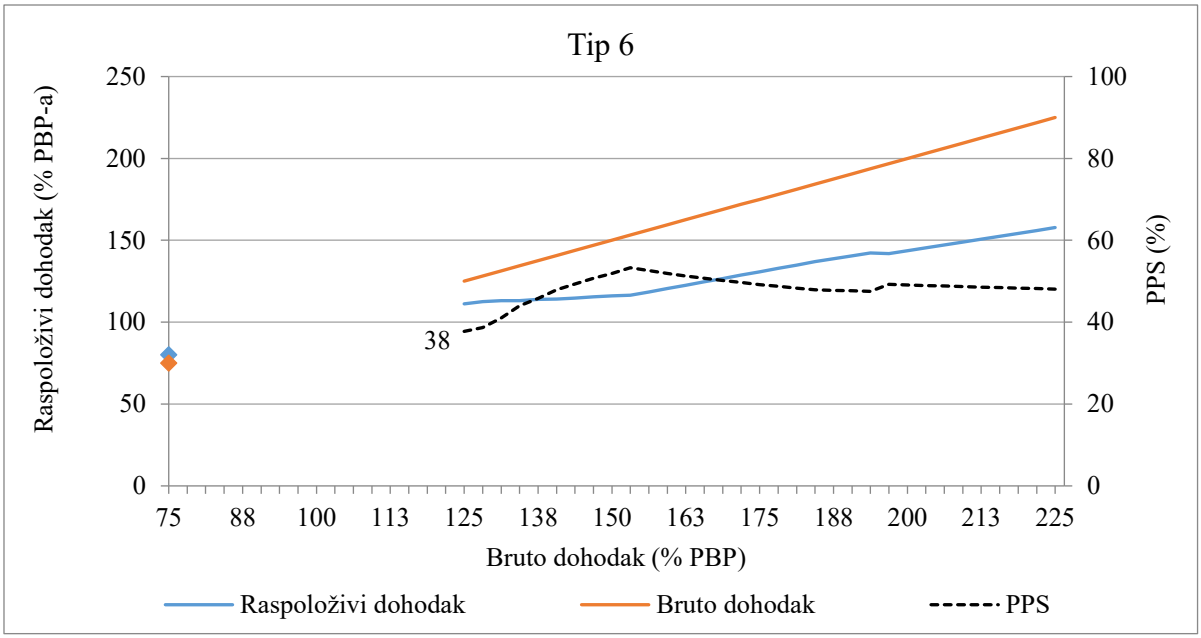
Slika 4.6. PPS i raspoloživi dohodak parova bez djece i s dvoje djece u kojima prvi supružnik razmatra zaposlenje, a drugi ne radi, Slovenija 2017.
Napomena: Na slici su izraženi iznosi PPS-a prilikom zapošljavanja uz minimalnu bruto plaću.
Izvor: Autorovi izračuni koristeći EUROMOD

Par s dvoje djece u kojemu se prvi supružnik zapošljava uz minimalnu bruto plaću, a drugi ne radi (tip 4) ima također visok PPS koji iznosi 80% (drugi dio slike 4.6.). Naime, raspoloživi dohodak u situaciji kada prvi supružnik ne radi iznosi 64% PBP-a (socijalna pomoć iznosi 40% PBP-a, naknada za troškove stanovanja 9% PBP-a, a doplatak za djecu 15% PBP-a), a raspoloživi dohodak prilikom zaposlenja uz minimalnu bruto plaću je 74% PBP-a (dohodak od plaće iznosi 39% PBP-a, doplatak za djecu i naknada za troškove stanovanja ostaju nepromijenjeni i redom

iznose 15% i 9% PBP-a, socijalna pomoć se smanjuje na 11% PBP-a). S povećanjem bruto plaće uz koju se prvi supružnik zapošljava povećava se i PPS koji svoju najveću vrijednosti od 85% doseže u slučaju kada se prvi supružnik zapošljava uz bruto plaću od 67% PBP-a. Glavni uzrok visokog PPS-a je potpuni prestanak prava na socijalnu pomoć i smanjenje iznosa doplatka za djecu na 12% PBP-a, dok naknada za troškove stanovanja ostaje 9% PBP-a, a dohodak od plaće iznosi 53% PBP-a. Dakle, raspoloživi dohodak kućanstva bi bio jednak u slučaju zaposlenja prvog supružnika uz minimalnu bruto plaću i uz bruto plaću od 67% PBP-a i iznosio bi 74% PBP-a. PPS opada s povećanjem bruto plaće do iznosa prosječne te iznosi 67%, a isti iznos poprima i u slučaju zapošljavanja prvog supružnika uz bruto plaću od 150% PBP-a.

Za razliku od prethodno spomenuta četiri tipa kućanstava, preostala dva tipa kućanstava u kojima drugi supružnik već radi uz bruto plaću od 75% PBP-a imaju dosta niži PPS prilikom zapošljavanja prvog supružnika. Tako za par bez djece u kojemu se prvi supružnik zapošljava uz minimalnu bruto plaću, a drugi radi uz bruto plaću od 75% PBP-a (tip 5) PPS iznosi 41% (prvi dio slike 4.7.). S daljnjim porastom bruto plaće PPS ostaje gotovo nepromijenjen te zapošljavanjem prvog supružnika uz bruto plaće od 100% i 200% PBP-a redom iznosi 42% i 44%.





Slika 4.7. PPS i raspoloživi dohodak parova bez djece i s dvoje djece u kojima prvi supružnik razmatra zaposlenje, a drugi je već zaposlen uz bruto plaću od 75% PBP-a, Slovenija 2017.
Napomena: Na slici su izraženi iznosi PPS-a prilikom zapošljavanja uz minimalnu bruto plaću.
Izvor: Autorovi izračuni koristeći EUROMOD

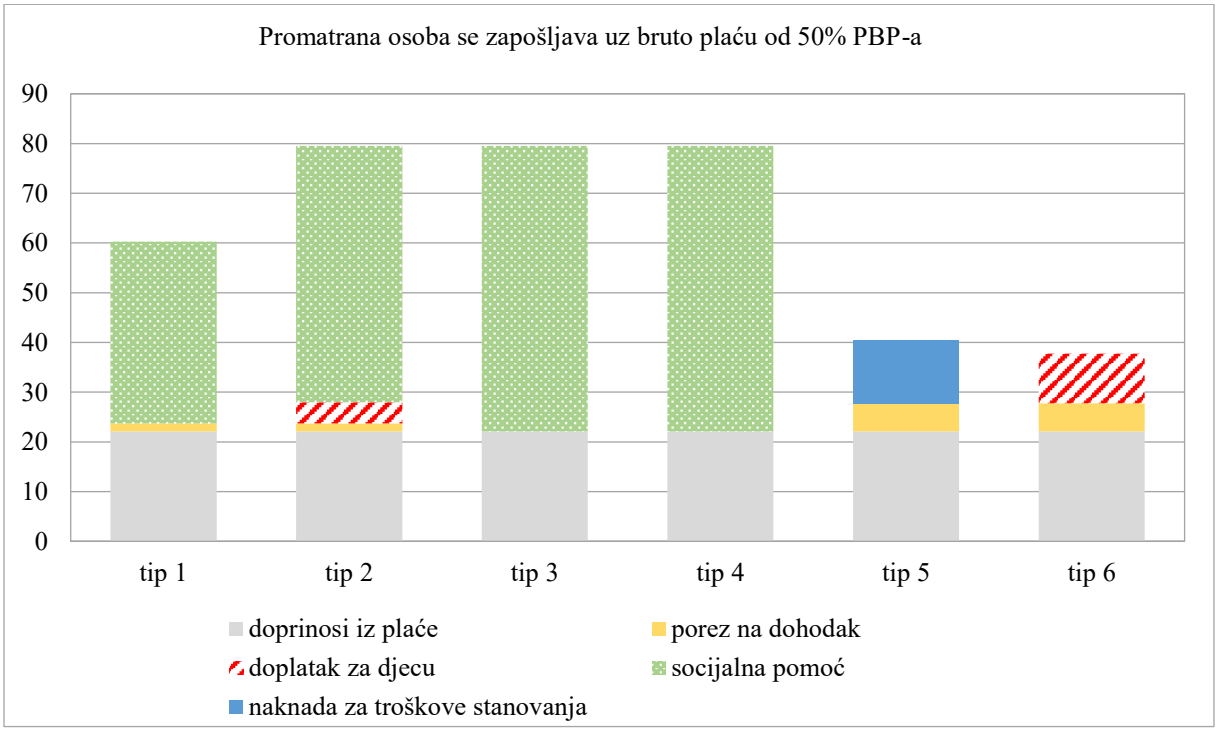
Za parove s dvoje djece u kojima se prvi supružnik zapošljava uz minimalnu bruto plaću, a drugi već radi uz bruto plaću od 75% PBP-a (tip 6) PPS iznosi 38%. PPS raste s postupnim povećanjem bruto plaće, a maksimalni iznos od 53% doseže prilikom zaposlenja prvog supružnika uz bruto plaću od 75% PBP-a. Spomenuti porast PPS-a posljedica je gubitka prava na doplatak za djecu i naknade za troškove stanovanja koje bi u situaciji kada prvi supružnik ne bi radio redom iznosile 12% i 9% PBP-a. Nakon spomenute razine bruto plaće PPS lagano pada pa zapošljavanjem prvog supružnika uz bruto plaću od 100% PBP-a PPS iznosi oko 49%, a s daljnjim povećanjem potencijalne bruto plaće uz koju se zapošljava prvi supružnik PPS ostaje gotovo neprimijenjen.

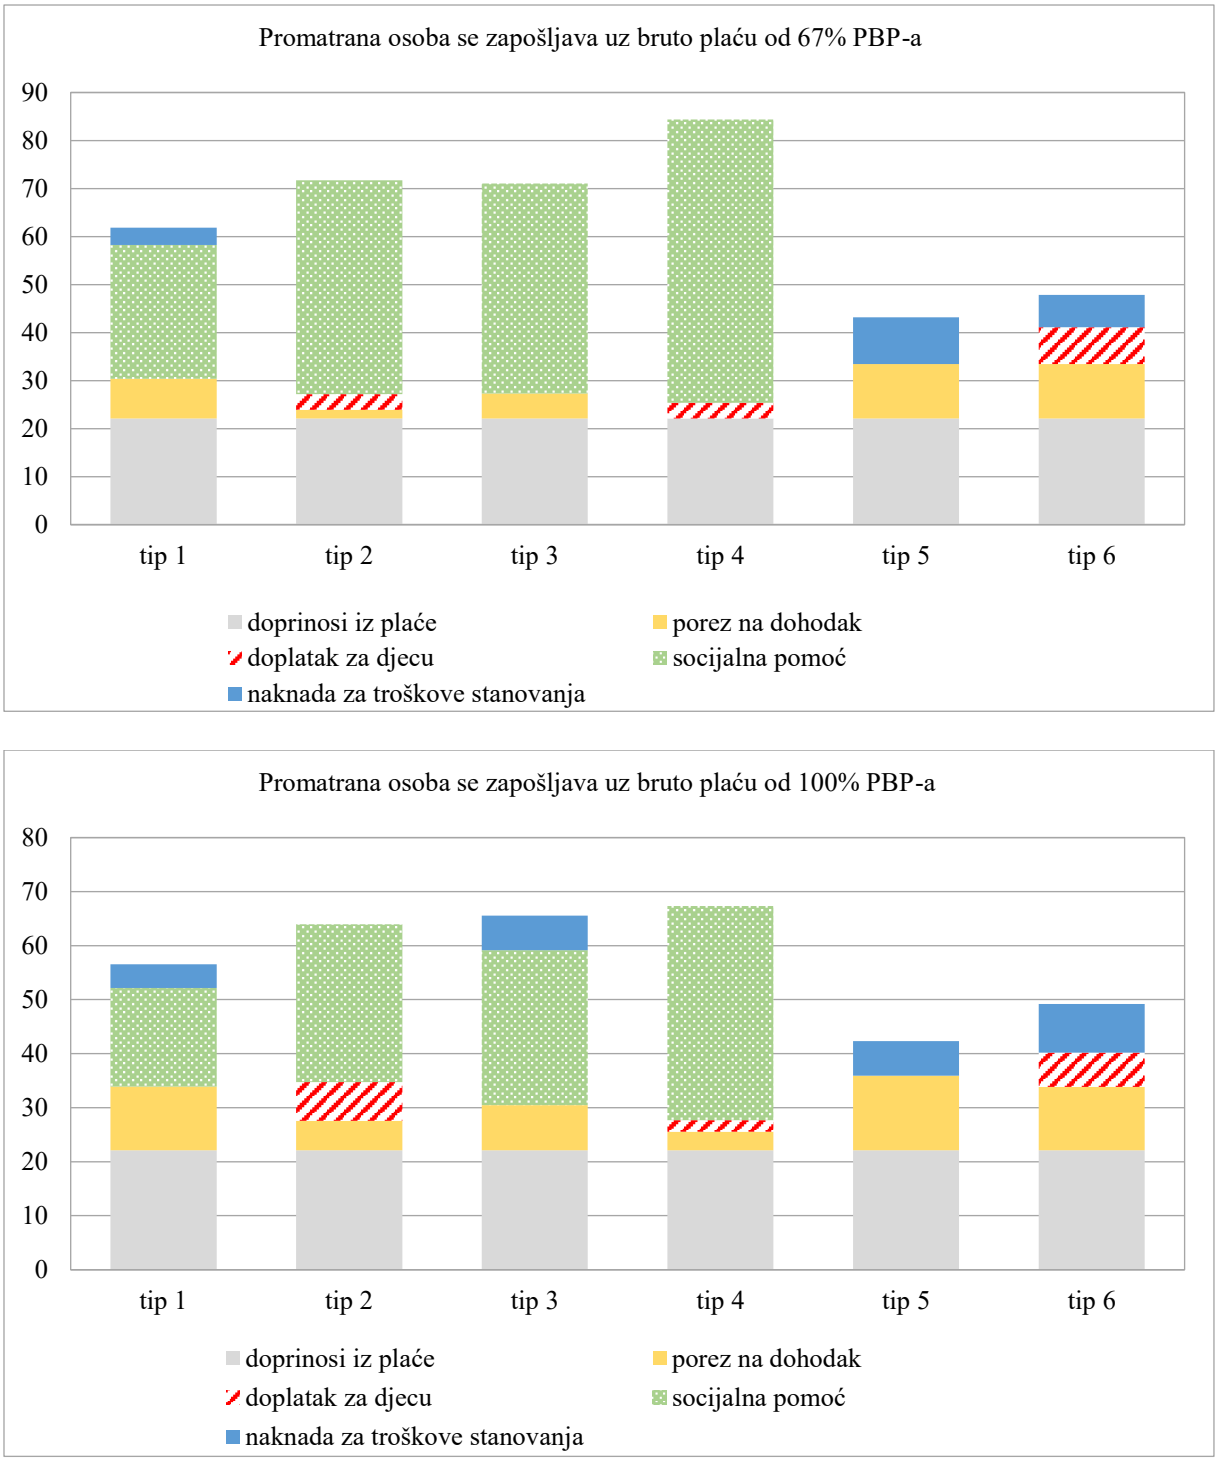
Na slici 4.8. se za šest promatranih tipova hipotetskih kućanstava analizira dekompozicija PPS-a za odabrane visine potencijalnih bruto plaća. Doprinos svake komponente sustava poreza i socijalnih naknada ukupnom PPS-u je prikazan drugom bojom (vidjeti legendu ispod dijagrama), a njihov zbroj jednak je ukupnoj vrijednosti PPS-a. Na slici je vidljivo da doprinosi iz plaće pridonose visini PPS-a s 22,1 postotnih bodova za sve tipove kućanstva i kod svih razina bruto plaća, dok se doprinos ostalih komponenti ukupnom PPS-u mijenja ovisno o visini potencijalne bruto plaće i tipu kućanstva.

U kućanstvima tipa 1 do 4 najveći doprinos ukupnom PPS-u daje socijalna pomoć. Za tipove 3 i 4, socijalna pomoć pridonosi ukupnom PPS-u s 58 postotnih bodova, što uz doprinose iz plaće daje ukupni PPS od 80%. Kućanstvo tipa 2 također ima PPS u iznosu od 80%, od čega je 52

postotnih bodova uzrokovano smanjenjem iznosa socijalne pomoći, 4 postotna boda smanjenjem iznosa doplatka za djecu, 2 postotna boda rezultat su poreza na dohodak, dok ostatak otpada na doprinose iz plaće. Kod kućanstva tipa 1, od ukupne vrijednosti PPS-a u iznosu od 60%, 36 postotnih bodova je uzrokovano gubitkom prava na socijalnu pomoć, a ostatak dolazi od doprinosa iz plaće i poreza na dohodak. Zanimljivo je napomenuti kako kućanstva tipa 1 do 4 imaju pravo na naknadu za troškove stanovanja, no iznos naknade u stanju kada promatrani član ne radi je jednak iznosu naknade na koju kućanstvo ima pravo u stanju kada bi se promatrani član zaposlio uz minimalnu bruto plaću, te zbog toga spomenuta naknada nema utjecaja na vrijednost PPS-a.

Za kućanstava tipa 5 i 6 u kojima se prvi supružnik zapošljava uz minimalnu bruto plaću, a drugi već radi uz bruto plaću od 75% PBP-a, najveći doprinos ukupnom PPS-u daje doprinos iz plaće. Osim toga, za kućanstvo tipa 5 porez na dohodak doprinosi ukupnom PPS-u sa 6, a naknada za troškove stanovanja s 13 postotnih bodova. Za kućanstvo tipa 6, doprinosi iz plaće i porez na dohodak zajedno doprinose ukupnom PPS-u s 28 postotnih bodova, dok smanjenje iznosa doplatka za djecu doprinosi s preostalih 10 postotnih bodova pa ukupni PPS iznosi 38%.





Slika 4.8. Dekompozicija PPS-a u Sloveniji u 2017. na razinama plaća od: (a) 50% PBP-a; (b) 67% PBP-a; (c) 100% PBP-a
Izvor: Autorovi izračuni koristeći EUROMOD

Općenito, iz sva tri dijela slike 4.8. je vidljivo da se s porastom potencijalne bruto plaće uz koju bi se zaposlila promatrana osoba smanjuje udio doprinosa socijalne pomoći ukupnom PPS-u. S druge strane, osim za kućanstvo tipa 5, doprinos naknade za troškove stanovanja ukupnom PPS-u raste s povećanjem potencijalne bruto plaće na 67% i 100% PBP-a što je uzrok činjenice da naknada za troškove stanovanja sporije iščezava s porastom bruto plaće nego socijalna

pomoć. Također, zbog progresivnog oporezivanja dohotka, s povećanjem potencijalne bruto plaće povećava se i doprinos poreza na dohodak ukupnom PPS-u. Tako na primjer doprinosi iz plaće i porez na dohodak doprinose ukupnom PPS-u iznosi 24 postotnih bodova za samce koji se zapošljavaju uz minimalnu bruto plaću, 30 postotnih bodova za samce koje zapošljavaju uz bruto plaću od 67% PBP-a, te 34 postotnih bodova za samce koji se zapošljavaju uz prosječnu bruto plaću. Naknada za troškove stanovanja nema utjecaja na PPS samaca koji rade uz minimalnu plaću, za samce koji rade uz 67% PBP-a doprinos iznosi 4 postotna boda, a za one koji rade uz prosječnu bruto plaću doprinos je 5 postotnih bodova. Doprinos socijalne pomoći ukupnom PPS-u redom iznosi 37, 28 i 18 postotnih bodova, ako se samac zapošljava na 40%, 67% i 100% PBP-a.

4.6. Empirijska analiza isplativosti rada u Republici Sloveniji

U ovom dijelu se na temelju anketnih podataka analizira distribucija PPS-a u Sloveniji prema različitim podskupinama neaktivnih i nezaposlenih osoba. Potom se procjenjuju odrednice vrlo visokog PPS-a u Sloveniji te se na koncu analizira dekompozicija PPS-a prema odabranim podskupinama. Analizira se 91 tisuća nezaposlenih i neaktivnih osoba koje čini 7% radno sposobne populacije (žena u dobi 18-60 i muškaraca u dobi 18-65). Metodologija izračuna PPS-a opisana je u dijelu 3.1., dok su anketni podaci opisani u dijelu 3.3.

Analiza počinje tablicom 4.16., koja pokazuje da prosječni PPS za neaktivne i nezaposlene osobe u Sloveniji iznosi 43,9%, pri čemu 21,9% promatranih osoba ima PPS između 50 i 70%, dok 5,2% osoba ima PPS iznad 70%. Tako u Sloveniji 27,1% neaktivnih i nezaposlenih osoba ima visok ili vrlo visok PPS.

Što se tiče podjele prema dobi, osobe mlađe dobi (18-30 godina) imaju najmanji PPS, 41,6%, ali imaju najveći udio osoba s vrlo visokim PPS-om od 7,9% i ima ih 17 tisuća. S druge strane, osobe srednje dobi (31-50) imaju najviši PPS od svih dobnih skupina koji iznosi 45,2%, a 6,2% ih ima vrlo visok PPS i ima ih 42 tisuće. Osoba starije dobi (51-65 godina) ima oko 32 tisuće, PPS im iznosi 43,4%, što je za oko 0,5 postotnih bodova manje od prosjeka za cjelokupnu populaciju neaktivnih i nezaposlenih osoba, a 2,5% ih ima vrlo visok PPS. Nadalje, muškarci imaju veći PPS od žena: PPS muškaraca iznosi 44,8%, a kod žena iznosi 43,4%. S druge strane, veći udio žena ima vrlo visok PPS, njih 5,5%, dok je taj postotak kod muškaraca nešto niži i iznosi 4,9%. Dodatno, neaktivnih i nezaposlenih žena ima ukupno ima 56 tisuća, a muškaraca ima oko 35 tisuća, te oko 1.700 muškaraca i 3.000 žena ima vrlo visok PPS u Sloveniji.

Tablica 4.16. Distribucija PPS-a prema određenim demografskim karakteristikama u Sloveniji (u %)

	Broj neaktivnih i nezaposlenih osoba (u tis.)	Prosječni PPS	Distribucija populacije prema razredima PPS-a			
			< 30 %	[30%, 50%>	[50%, 70%>	≥ 70%
Ukupno	91	43,9	5,5	67,4	21,9	5,2
Dob						
18-30	17	41,6	9,6	73,7	8,7	7,9
31-50	42	45,2	4,3	67,1	22,4	6,2
51-65	32	43,4	4,8	64,6	28,1	2,5
Spol						
Muško	35	44,8	5,5	64,2	25,4	4,9
Žensko	56	43,4	5,4	69,5	19,6	5,5
Obrazovanje						
Srednje	75	44,7	6,4	62,8	24,4	6,4
Više/visoko	16	40,5	0,9	89,1	10,1	0,0
Broj djece						
Nema djece	60	41,7	7,2	70,7	19,9	2,2
Jedno dijete	18	47,5	2,6	61,6	26,7	9,1
Dva djeteta	10	50,3	0,7	58,4	27,1	13,8
Troje ili više djece	3	47,9	2,1	65,4	17,1	15,4
Tržišni dohodak ostalih članova kućanstva (u EUR)						
0 do 50	16	57,2	0,2	35,1	44,6	20,1
50 do 500	12	50,6	2,0	46,4	43,9	7,7
500 do 1.000	17	42,7	8,4	68,3	20,8	2,5
1.000 do 2.000	22	38,3	8,1	83,5	8,0	0,5
više od 2.000	24	37,4	6,4	85,2	8,3	0,1

Izvor: Autorovi izračuni koristeći EUROMOD

Za razliku od Hrvatske, u uzorku za Sloveniju nema punoljetnih osoba koje imaju samo osnovni stupanj obrazovanja pa se u smislu analize PPS-a promatraju samo osobe sa srednjim i višim/visokim stupnjem obrazovanja. Osoba sa srednjim stupnjem obrazovanja ima 76 tisuća, što je skoro 5 puta više nego osoba s višim/visokim stupnjem obrazovanjem kojih ima 16 tisuća. Prosječni PPS za osobe sa srednjim stupnjem obrazovanja je 44,7%, a 6,2 posto takvih osoba ima vrlo visok PPS. Osobe s višim/visokim stupnjem obrazovanja imaju PPS za 3,5 postotnih bodova niži od prosjeka za sve neaktivne i nezaposlene osobe, a takve osobe nemaju problema s vrlo visokim PPS-om.

Očekivano, PPS raste s brojem maloljetne djece u kućanstvima, pa PPS osoba koje nemaju djece iznosi 41,7%, dok PPS osoba s dvoje djece iznosi 50,3%, a onih s troje ili više djece iznosi 47,9%. Također, puno veći udio osoba s troje ili više djece, njih 15,4%, i osoba s dvoje djece, njih 13,8%, ima vrlo visok PPS, za razliku od osoba bez djece kojih tek 2,2% ima vrlo visok PPS. Nadalje, PPS se razlikuje ovisno o visini tržišnog dohotka ostalih članova kućanstva. Osobe čiji članovi kućanstva ostvaruju tržišni dohodak manji od 50 eura imaju najveći PPS koji iznosi 57,2%, a 20,1% takvih osoba ima vrlo visok PPS. S druge strane,

najmanji PPS u iznosu od 37,4% imaju osobe čiji članovi kućanstva ostvaruju tržišni dohodak veći od 2 tisuće eura, a tek 0,1% takvih osoba ima vrlo visok PPS.

Na temelju prethodno iznesenih rezultata pokazalo se kako određene podskupine imaju vrlo visok PPS. Da bi se otkrile odrednice vrlo visokog PPS-a, u tablici 4.17. su prikazani procijenjeni parametri i granični utjecaji provedenog logit modela. Granični utjecaj mjeri kako jedinična promjena odabrane nezavisne varijable utječe na vjerojatnost vrlo visokog PPS-a, uz uvjet da su sve ostale varijable konstantne, odnosno da se nalaze na svojim prosječnim vrijednostima.

Rezultati iz tablice 4.17. pokazuju da vjerojatnost vrlo visokog PPS-a raste s brojem djece, a opada s godinama i visinom tržišnog dohotka ostalih članova kućanstva. Granični utjecaji pokazuju da je, uz ostale varijable konstantne, za osobe s troje ili više djece u prosjeku za 1,8 postotnih bodova vjerojatnije da će imati vrlo visok PPS nego za osobe bez djece, a osobe mlađe dobi imaju u prosjeku za 1 postotni bod veću vjerojatnost vrlo visokog PPS-a od osoba starije dobi. Također, vjerojatnost vrlo visokog PPS-a je u prosjeku za 1,1 postotni bod niža sa svakim porastom tržišnog dohotka ostalih članova kućanstva za tisuću eura.

Tablica 4.17. Procjena vjerojatnosti vrlo visokog PPS-a u Sloveniji logit modelom

	Procijenjeni parametri (standardna pogreška)	Granični utjecaj
Dob (bazna: 51-65)		
18-30	1,820 (0,400)***	0,010
31-50	0,334 (0,391)	0,002
Spol (bazna: muško)		
Žensko	0,129 (0,295)	0,001
Broj djece (bazna: bez djece)		
Jedno dijete	1,691 (0,340)***	0,013
Dva djeteta	1,803 (0,418)***	0,015
Troje ili više djece	1,979 (0,516)***	0,018
Tržišni dohodak ostalih članova kućanstva (u tis. EUR)	-2,091 (0,271)***	-0,011
Konstanta	-2,499 (0.362)***	
Broj opažanja	1.175	
Broj opažanja s vrlo visokim PPS-om	63	
Prob > chi2	0,000	
Pseudo R2	0,362	

*Signifikantnost: *p<0,1, **p<0,05, ***p<0,01*
Izvor: izračuni autora

Nadalje tablica 4.18. prikazuje dekompoziciju PPS-a prema različitim podskupinama nezaposlenih i neaktivnih osoba. U stupcima (1) do (6) se prikazuje doprinos određenih elemenata ukupnom PPS-u, a njihov zbroj se nalazi u stupcu (7) koji označava ukupni PPS. Doprinosi iz plaće (stupac 1) imaju jednak doprinos PPS-u od 22,1 postotnih bodova za sve

podskupine, a to je ujedno i najznačajniji čimbenik ukupnog PPS-a. Na razini svih neaktivnih i nezaposlenih osoba doprinos poreza na dohodak (stupac 2) iznosi 9,6 postotnih bodova, a najveći doprinos tog elementa ukupnom PPS-u ima prisutan je za osobe s višim/visokim obrazovanjem (12,2 postotnih bodova), osobe starije generacije (10,5 postotnih bodova) i osobe bez djece (10,4 postotnih bodova).

Doplatak za djecu (stupac 3) ima najveći doprinos ukupnom PPS-u od 5,5 postotnih bodova za podskupinu osoba s troje ili više djece, a doprinos tog elementa na razini svih neaktivnih i nezaposlenih osoba iznosi 1,2 postotnih bodova. Što se tiče socijalne pomoći (stupac 4), najveći doprinos ukupnom PPS-u imaju osobe s djecom. Za osobe s jednim djetetom doprinos iznosi 11,8, za osobe s troje ili više djece iznosi 14,1 postotnih bodova, dok prosječni doprinos iznosi 8,4 postotnih bodova. Nadalje, kao i u Hrvatskoj, duljina razdoblja primanja naknade za nezaposlene ovisi o vremenskom razdoblju provedenom na prethodnom poslu, pa tako najveći doprinos te naknade ukupnom PPS-u od 4,7 postotnih bodova ima podskupina osoba od 51 do 65 godina, a prosječni doprinos iznosi 2,6 postotnih bodova.

Tablica 4.18. Dekompozicija PPS-a prema različitim podskupinama u Sloveniji

	DIP	PND	DPZD	SOCN	NZN	UK PPS
	(1)	(2)	(3)	(4)	(5)	(6)
Ukupno	22,1	9,6	1,2	8,4	2,6	43,9
Dob						
18-30	22,1	9,1	0,9	8,7	0,8	41,6
31-50	22,1	9,1	1,9	10,3	1,8	45,2
51-65	22,1	10,5	0,3	5,8	4,7	43,4
Spol						
Muško	22,1	9,9	0,6	8,8	3,4	44,8
Žensko	22,1	9,4	1,6	8,1	2,2	43,4
Obrazovanje						
Srednje	22,1	9,1	1,2	9,5	2,8	44,7
Više/visoko	22,1	12,2	1,1	3,3	1,8	40,5
Broj djece						
Nema djece	22,1	10,4	0,0	6,1	3,1	41,7
Jedno dijete	22,1	8,8	2,7	11,8	2,1	47,5
Dva djeteta	22,1	7,5	4,5	14,9	1,3	50,3
Troje ili više djece	22,1	5,3	5,5	14,1	0,9	47,9

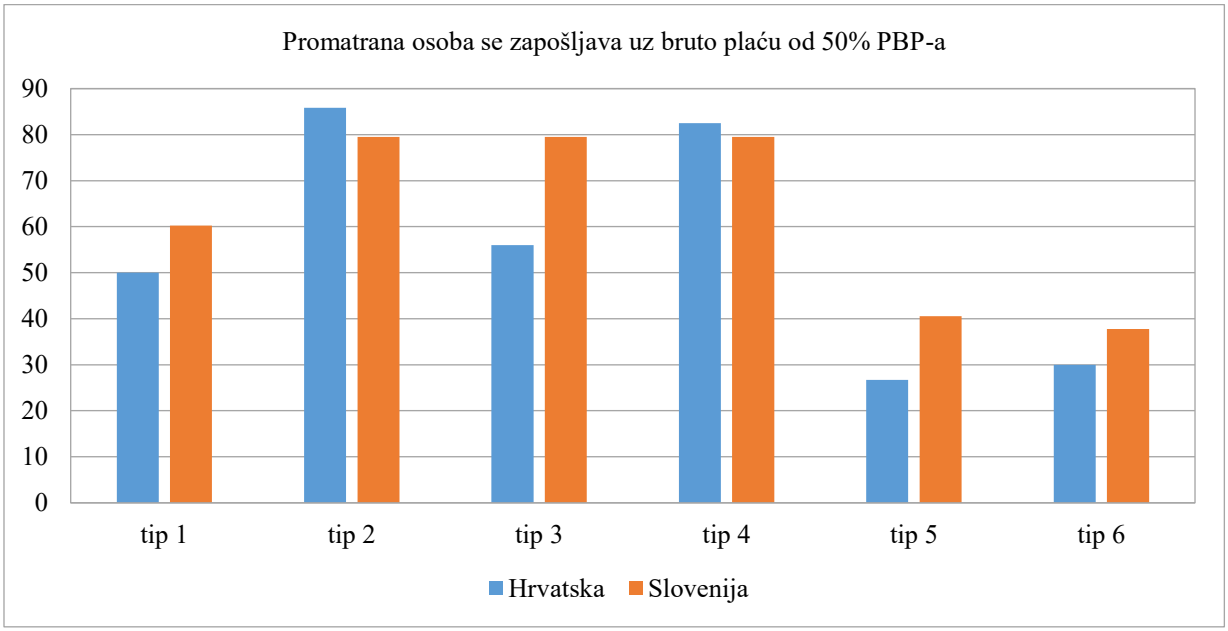
Kratice: DIP – doprinos iz plaće; PND – porez na dohodak; DPZD – doplatak za djecu; SOCN – socijalna pomoć i naknada za troškove stanovanja; NZN – naknada za nezaposlene; UK PPS – ukupni PPS.
Izvor: Autorovi izračuni koristeći EUROMOD

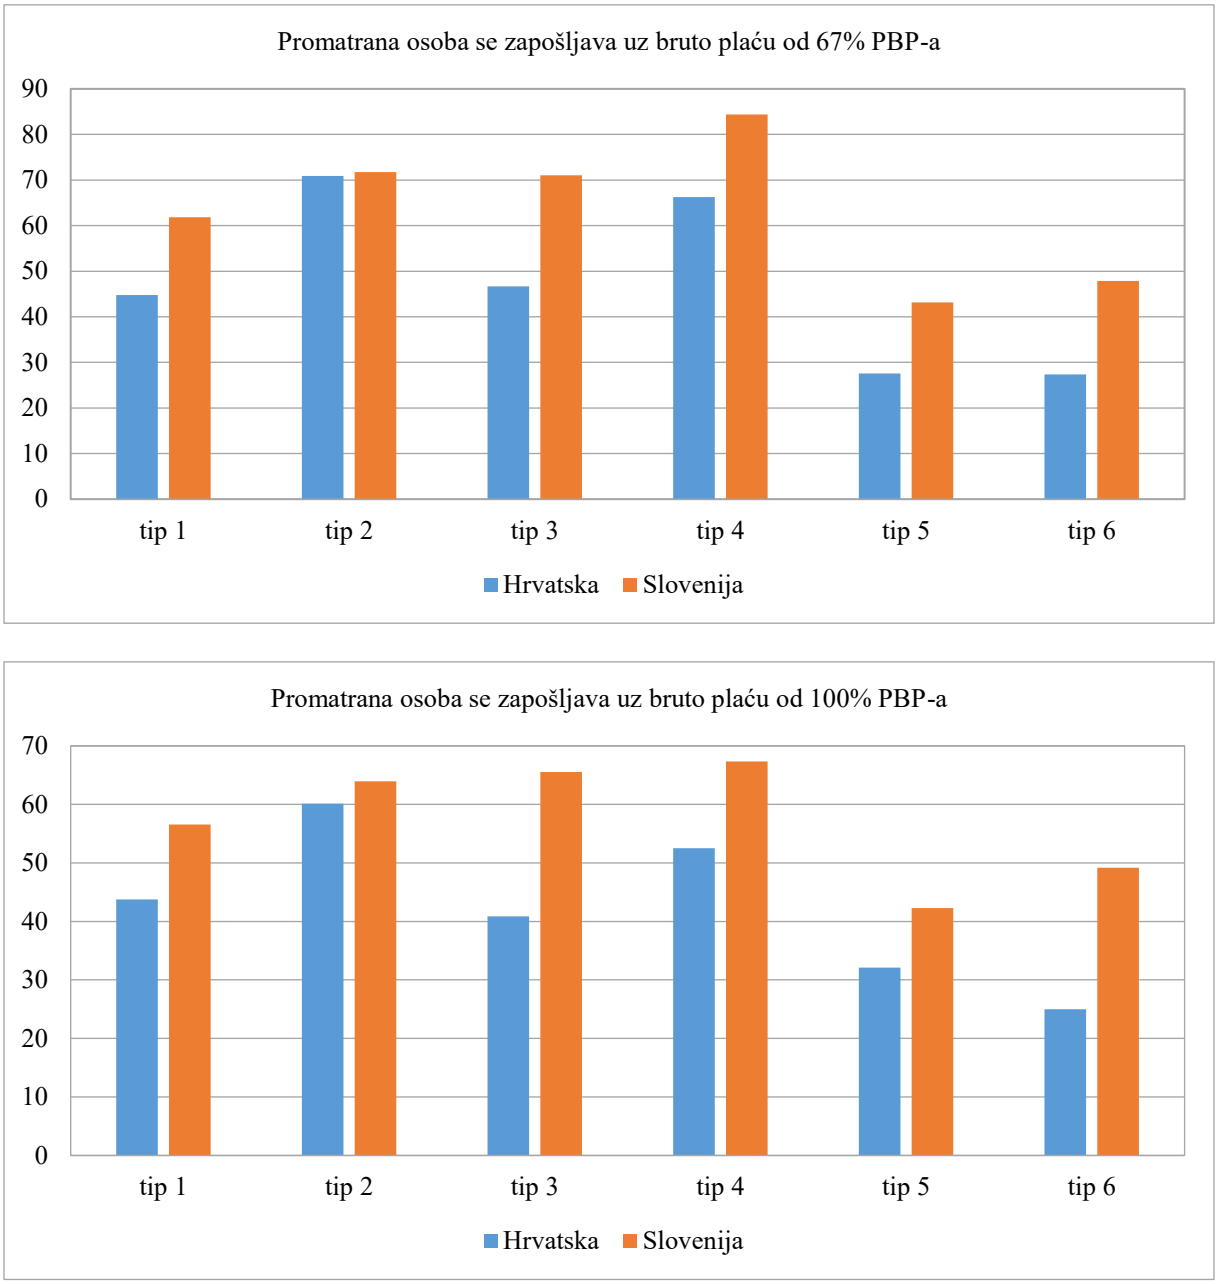
4.7. Komparativna analiza isplativosti rada za Republiku Hrvatsku i Republiku Sloveniju

U ovom dijelu se provodi komparativna analiza pokazatelja isplativosti rada za Hrvatsku i Sloveniju. Time se nastoji utvrditi kako u pogledu isplativosti rada Hrvatska stoji u usporedbi sa

susjednom zemljom Slovenijom. Komparativna analiza počinje analizom grafičkih prikaza (slika 4.9.) na kojoj je dan PPS za šest odabranih tipova kućanstava u kojima se promatrana osoba zapošljava uz bruto plaće od 50%, 67% i 100% PBP-a. Za sve tri spomenute razine bruto plaće uz koje se promatrani član kućanstva zapošljava, PPS je u Hrvatskoj uglavnom niži nego u Sloveniji. Iznimka su kućanstva tipa 2 i tipa 4 u kojima se promatrani član zapošljava uz bruto plaću od 50% PBP-a, jer je za takva kućanstva PPS nešto veći u Hrvatskoj nego u Sloveniji. Preciznije, za kućanstvo tipa 2, PPS u Hrvatskoj iznosi 86%, što je za 6 postotnih bodova veće nego u Sloveniji, dok za kućanstvo tipa 4 PPS u Hrvatskoj iznosi 82%, a u Sloveniji 80%. Za ostale tipove kućanstava, u kojima se promatrani član zapošljava uz bruto plaću od 50% PBP-a, PPS je veći u Sloveniji. Najveća razlika od 24 postotnih bodova je prisutna kod kućanstva tipa 3, za koje PPS u Sloveniji iznosi 80%, a u Hrvatskoj 56%.

Zapošljavanjem promatranog člana kućanstva uz bruto plaće od 67% i 100% PBP-a, najveća razlika između PPS-a u Hrvatskoj i Sloveniji je i dalje prisutna kod kućanstva tipa 3 kod kojeg je uz obje razine bruto plaće PPS u Sloveniji za 24 postotnih bodova viši nego u Hrvatskoj. Tako, kada se promatrani član iz kućanstva tipa 3 zapošljava uz bruto plaću od 67% PBP-a, PPS u Sloveniji iznosi 71%, a u Hrvatskoj je 47%. Nadalje, zapošljavanjem uz prosječnu bruto plaću, PPS iznosi 66% u Sloveniji, a 42% u Hrvatskoj. Veća razlika između PPS-a u promatranim državama prisutna je i kod kućanstva tipa 6. Zapošljavanjem promatranog odraslog člana uz bruto plaću od 67% PBP-a, PPS u Sloveniji iznosi 48%, a u Hrvatskoj je niži za 20 postotnih bodova. S druge strane, prilikom zapošljavanja uz bruto plaću od 100% PBP-a, razlika između država je izraženija (24 postotnih bodova) budući da PPS u Sloveniji iznosi 49%, a u Hrvatskoj 25%.





Slika 4.9. Komparativna analiza PPS-a između Hrvatske i Slovenije u 2017. za odabrane tipove kućanstva na razinama plaća od: (a) 50% PBP-a; (b) 67% PBP-a; (c) 100% PBP-a
Izvor: Autorovi izračuni koristeći EUROMOD

Komparativna analiza PPS-a na temelju anketnih podataka je potvrdila rezultate dobivene na hipotetskim kućanstvima koji pokazuju da Slovenija ima veći prosječni PPS nego Hrvatska (tablica 4.19.). Preciznije, analiza otkriva da je prosječni PPS u Sloveniji za 12,7 postotnih bodova veći nego u Hrvatskoj; prosječni PPS u Sloveniji iznosi 43,9%, dok u Hrvatskoj iznosi 31,2%. Nadalje, u Sloveniji 21,9% osoba izvan rada ima visok PPS, a 5,2% ih ima vrlo visok PPS. S druge strane, 6,2% osoba izvan rada u Hrvatskoj ima visok PPS, a 2,8% ih ima vrlo visok PPS. Tako 27,1% osoba izvan rada ima visok i vrlo visok PPS u Sloveniji, dok u Hrvatskoj 9%

osoba izvan rada ima visok i vrlo visok PPS. Time se potvrdila hipoteza **H1b** koja tvrdi da Slovenija ima veći prosječni PPS i veći udio osoba izvan rada s visokom i vrlo visokom PPS-om nego Hrvatska. No valja naglasiti da Hrvatska ima više nego dvostruko veći udio neaktivnih i nezaposlenih osoba u radno sposobnoj populaciji: u Hrvatskoj je 17% radno sposobne populacije neaktivno ili nezaposleno, dok ih je u Sloveniji 7% neaktivno ili nezaposleno.

Tablica 4.19. Komparativna analiza distribucije PPS-a između Hrvatske i Slovenije (u %)

	Hrvatska			Slovenija		
	Prosječni PPS	Distribucija populacije prema razredima PPS-a		Prosječni PPS	Distribucija populacije prema razredima PPS-a	
		[50%, 70%>	≥ 70%		[50%, 70%>	≥ 70%
Ukupno	31,2	6,2	2,8	43,9	21,9	5,2
Dob						
18-30	27,1	3,5	0,8	41,6	8,7	7,9
31-50	32,4	8,4	3,5	45,2	22,4	6,2
51-65	31,9	5,0	2,4	43,4	28,1	2,5
Spol						
Muško	32,1	8,1	1,6	44,8	25,4	4,9
Žensko	30,3	5,0	3,2	43,4	19,6	5,5
Obrazovanje						
Osnovno	43,9	12,4	14,0	-	-	-
Srednje	30,7	6,6	2,3	44,7	24,4	6,4
Više/visoko	29,6	0,5	1,0	40,5	10,1	0,0
Broj djece						
Nema djece	29,8	5,4	1,1	41,7	19,9	2,2
Jedno dijete	30,7	5,5	4,0	47,5	26,7	9,1
Dva djeteta	31,1	7,0	3,7	50,3	27,1	13,8
Troje ili više djece	38,8	12,0	7,2	47,9	17,1	15,4

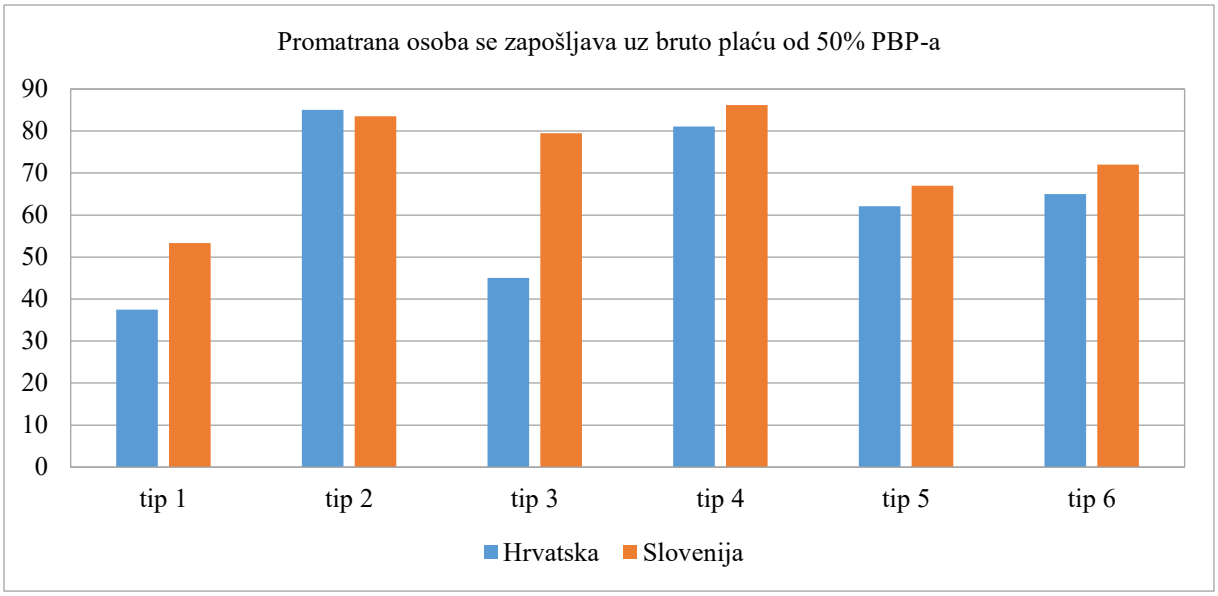
Izvor: Autorovi izračuni koristeći EUROMOD

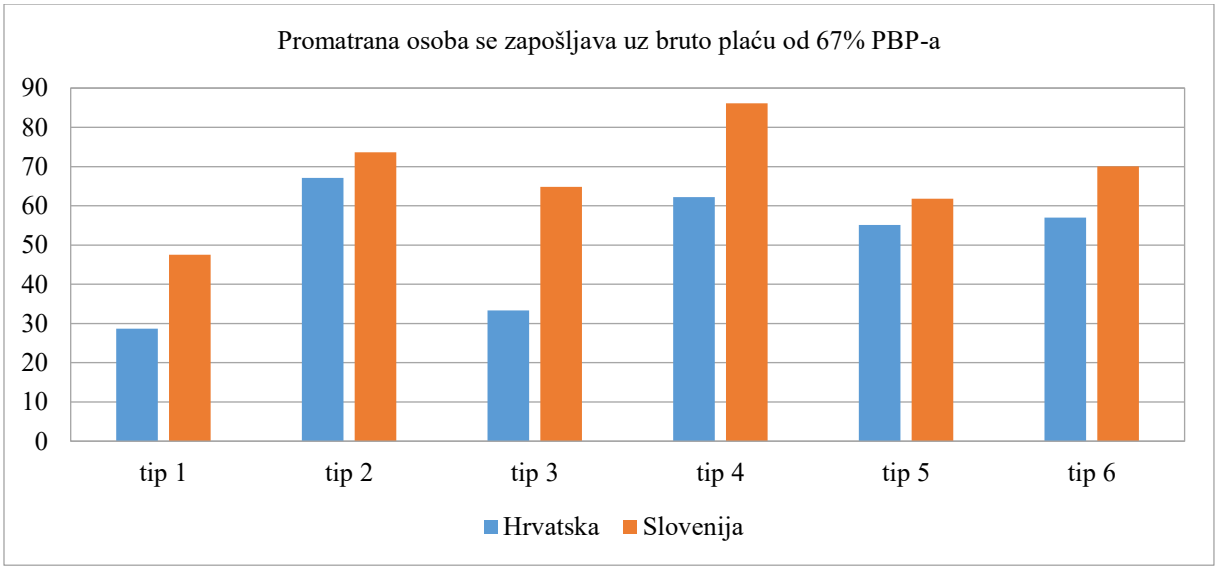
Komparativna analiza prema odabranim podskupinama otkriva da je za svaku promatranu podskupinu osoba izvan rada prosječni PPS veći u Sloveniji nego u Hrvatskoj. U Sloveniji najveći udio osoba s vrlo visokim PPS-om od 15,4% ima podskupina osoba s troje ili više djece, a u Hrvatskoj je taj udio za 8,2 postotnih bodova manji. U Hrvatskoj pak najveći udio osoba s vrlo visokim PPS-om od 14% ima podskupina s osnovnim stupnjem obrazovanja, dok u Sloveniji niti jedna odrasla osoba nema niži stupanj obrazovanja od srednjeg pa taj podatak za Sloveniju ne postoji. Međutim, 6,4% osoba s srednjim stupnjem obrazovanja u Sloveniji ima vrlo visok PPS, a u Hrvatskoj je taj udio manji za 4,1 postotnih bodova. Što se tiče podjele prema spolu, pokazalo se da u Sloveniji veći udio muškaraca i žena ima vrlo visok PPS nego u Hrvatskoj. Točnije, 5,5% žena u Sloveniji ima vrlo visok PPS, što je za 2,3 postotnih bodova više nego u Hrvatskoj. U obje države muškarci imaju manji udio osoba s vrlo visokim PPS-om nego žene, a taj udio u Sloveniji iznosi 4,9%, dok je u Hrvatskoj za 3,3 postotnih bodova manji.

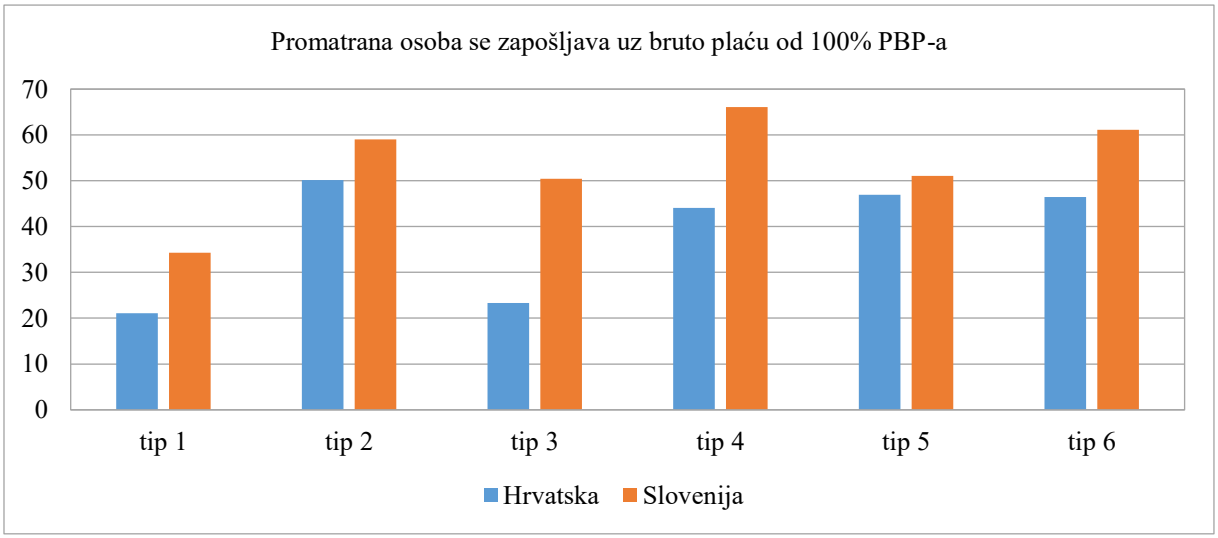
U nastavku se analizira NSZ koji se koristi kao alternativni pokazatelj isplativosti rada. Na slici 4.10 dana je komparativna analiza NSZ-a na hipotetskim kućanstvima uz tri potencijalne razine bruto plaće uz koje promatrani član razmatra zaposlenje. Rezultati pokazuju da je za sve tipove kućanstva i na svim razinama bruto plaća NSZ u Sloveniji uglavnom veći nego u Hrvatskoj. Iznimka je kućanstvo tipa 2 koje prilikom zaposlenja samohranog roditelja uz bruto plaću od 50% PBP-a ima veći NSZ u Hrvatskoj nego u Sloveniji i to je ujedno i kućanstvo s najvećim NSZ-om u Hrvatskoj. Međutim, razlika iznosi samo jedan postotni bod, za kućanstvo tipa 2 u Hrvatskoj je NSZ 85%, a u Sloveniji 84%. U svim ostalim slučajevima Slovenija ima veći NSZ od Hrvatske, a najveći NSZ u Sloveniji ima kućanstvo tipa 4 u kojemu se odrasli član zapošljava uz bruto plaće od 50% ili 67% PBP-a, kod kojih je NSZ jednak 86%. To znači da takvo kućanstvo u stanju kada promatrani član ne radi ostvaruje 86% od potencijalnog raspoloživog dohotka kojeg bi kućanstvo moglo ostvariti ako bi promatrani član bio zaposlen uz spomenute bruto plaće od 50% i 67% PBP-a. Što se tiče usporedbe Hrvatske i Slovenije za kućanstvo tipa 4, zapošljavanjem prvog supružnika uz bruto plaću od 50% PBP-a, NSZ je u Hrvatskoj za 5 postotnih bodova niži nego u Sloveniji. Nadalje, u slučaju zaposlenja promatranog člana uz bruto plaću od 67% PBP-a NSZ je u Hrvatskoj niži za čak 24 postotnih bodova.

Najveća razlika između NSZ-a u Hrvatskoj i Sloveniji je prisutna kod kućanstva tipa 3. Zapošljavanjem promatranog člana tog kućanstva uz bruto plaće od 50%, 67% i 100% PBP-a, NSZ u Sloveniji redom iznosi 80%, 65% i 50% što je za 35, 32 i 27 postotnih bodova veće nego u Hrvatskoj. Nadalje, u Hrvatskoj i Sloveniji najmanji NSZ imaju samci koji zapošljavanjem uz bruto plaće od 50% ,67% i 100% PBP-a u Hrvatskoj imaju NSZ od 38%, 29% i 21%, što je redom niže za 16, 19 i 13 postotnih bodova nego u Sloveniji.

Dodatno, zanimljivo je primijetiti da u usporedbi s ostalim kućanstvima, kućanstva tipa 5 i 6 koja imaju najniži PPS u obje zemlje nemaju ujedno i najniži NSZ. Razlog tome je što u spomenutim kućanstvima drugi supružnik već radi a prvi se zapošljava pa prihod drugog člana kućanstva utječe na visinu NSZ-a. Preciznije, što je veći prihod ostalih članova kućanstava veći je i NSZ. Tako za kućanstva tipa 5 i 6 u kojima se promatrani član zapošljava uz bruto plaću od 50% PBP-a NSZ u Hrvatskoj redom iznosi 62 i 65%, dok je u Sloveniji veći za 5, odnosno 7 postotnih bodova.







Slika 4.10. Komparativna analiza NSZ-a između Hrvatske i Slovenije u 2017. za odabrane tipove kućanstva na razinama plaća od: (a) 50% PBP-a; (b) 67% PBP-a; (c) 100% PBP-a
Izvor: Autorovi izračuni koristeći EUROMOD

Empirijska analiza NSZ-a za Hrvatsku i Sloveniju (tablica 4.20.) pokazuje da je prosječni NSZ veći u Hrvatskoj nego u Sloveniji, što je suprotno s rezultatima PPS-a.[25] Spomenutu činjenicu spominju Myck i sur. (2015) koji na temelju istraživanja provedenog za Poljsku navode da se zaključci o poticajima za rad na ekstenzivnoj granici ponude rada mogu razlikovati ovisno o tome promatra li se kao pokazatelj PPS ili NSZ. Također navode da se razlike u kretanju PPS-a i NSZ-a posebno pojavljuju u slučaju kada u kućanstvu postoje ostali članovi koji imaju svoja primanja. U ovom istraživanju se uzrok različitih kretanja PPS-a i NSZ-a pripisuje dohotku ostalih članova kućanstva. Naime, što je veći udio ostalih članova kućanstva, veći je i NSZ, dok PPS ostaje nepromijenjen.

Tablica 4.20. Komparativna analiza distribucije NSZ-a između Hrvatske i Slovenije (u %)

	Hrvatska			Slovenija		
	Prosječni NSZ	Distribucija populacije prema razredima NSZ-a		Prosječni NSZ	Distribucija populacije prema razredima NSZ-a	
		[50%, 70%>	≥ 70%		[50%, 70%>	≥ 70%
Ukupno	61,0	36,6	36,7	57,4	48,9	23,3
Dob						
18-30	63,1	43,7	37,9	63,7	48,3	37,6
31-50	62,7	37,3	38,7	57,8	53,6	21,1
51-65	56,5	30,2	32,6	53,6	43,1	18,6
Spol						
Muško	51,5	36,7	18,7	53,9	43,6	20,1
Žensko	67,8	36,6	49,6	59,7	52,3	25,3
Obrazovanje						
Osnovno	67,3	22,6	53,8	-	-	-
Srednje	61,1	36,5	37,4	58,6	48,8	25,7
Više/visoko	57,0	43,5	22,6	52,0	49,3	12,0
Broj djece						
Nema djece	57,4	34,1	31,6	53,8	43,5	18,7
Jedno dijete	62,2	42,0	34,9	62,8	60,3	28,0
Dva djeteta	66,5	44,7	41,9	65,5	60,6	34,4
Troje ili više djece	72,6	32,0	62,7	69,9	51,6	48,4

Izvor: Autorovi izračuni koristeći EUROMOD

Rezultati za Hrvatsku i Sloveniju su pokazali da prosječni NSZ u Hrvatskoj iznosi 61,0% što je 3,6 postotnih bodova više nego u Sloveniji. Nadalje, veći udio osoba izvan rada u Hrvatskoj ima vrlo visok NSZ (veći ili jednak 70%), njih 36,7%, dok je u Sloveniji taj udio za 13,4 postotnih bodova manji. U obje zemlje najveći NSZ ima podskupina osoba s troje ili više djece, kod kojih je NSZ u Hrvatskoj jednak 72,6% što je za 2,7 postotnih bodova veće nego u Hrvatskoj. Spomenuta podskupina ima i najveći udio osoba s vrlo visokim NSZ-om, u Hrvatskoj taj udio iznosi 62,7%, dok je u Sloveniji za 14,3 postotnih bodova niži. Drugi

[25] Neki od uzroka različitih kretanja PPS-a i NZS-a su opisani u poglavlju 3.1.3.

najviši NSZ u Hrvatskoj od 67,8% ima podskupina ženskih osoba, dok je u Sloveniji za 8,1 postotnih bodova manji. Dodatno, 49,6% žena ima vrlo visok NSZ, a u Sloveniji taj udio iznosi 25,3%. S druge strane, podskupina muških osoba ima najniži NSZ u Hrvatskoj od 51,5%, što je za 2,4 postotnih bodova manje nego u Sloveniji. Udio muških osoba s vrlo visokim NSZ-om je također niži u Hrvatskoj gdje iznosi 18,7%, a u Sloveniji je viši za 1,4 postotnih bodova viši.

5. UVOĐENJE POLITIKA ZA POVEĆANJE ISPLATIVOSTI RADA

U drugom poglavlju se pokazalo da se unutar EU-a Hrvatska nalazi među zemljama s najnižom stopom zaposlenosti, koja je u 2017. iznosila 63,6%. Također se pokazalo da udio zaposlenih i nezaposlenih osoba u populaciji (20-64) iznosi 70%, te da bez uključivanja neaktivnih osoba na tržište rada (kojih ima 10% od ukupne populacije u dobi 20-64) Hrvatska ne može doseći ciljanu stopu zaposlenosti za 2020. od najmanje 75%. Dodatno se pokazalo da je Hrvatska jedna od zemalja EU-a s najnižom stopom zaposlenosti žena, pa Europska komisija (2017a) navodi da uz problem starenja stanovništva i nisku stopu zaposlenosti žena Hrvatska ima veliki potencijal za povećanje radne snage kroz uključivanje žena u radnu snagu. Nadalje, u četvrtom poglavlju je pokazano da u Hrvatskoj i Sloveniji određeni tipovi kućanstava kao i određene podskupine osoba izvan rada imaju vrlo niske poticaje za rad. Stoga se u ovom poglavlju analizira uvođenje politika za povećanje isplativosti u hrvatski i slovenski sustav poreza i socijalnih naknada kako bi se potaklo nezaposlene i neaktivne osobe da se uključe u svijet rada.[26]

5.1. Učinci uvođenja politika za povećanje isplativosti rada u Republici Hrvatskoj

U ovom dijelu se analizira uvođenje tri tipa naknada za zaposlene u hrvatski sustav poreza i socijalnih naknada. Prvo se provodi analiza na hipotetskim kućanstvima, a potom slijedi analiza isplativosti rada na temelju anketnih podataka.

5.1.1. Definicije reformskih politika u Republici Hrvatskoj

U hrvatski sustav se ugrađuju tri reforme, odnosno tri tipa naknada za zaposlene. Prve dvije reforme obuhvaćaju uvođenje modificiranih naknada koje su preuzete iz UK-a, gdje se takva naknada zove WTC (engl. *Working tax credit*), dok se u trećoj reformi preuzima slovački tip naknade za zaposlene ETC (engl. „*Employee tax credit*“).[27] Zadržat će se osnovna obilježja spomenutih politika, no uvode se razne prilagodbe i pojednostavljenja.

U stvarnosti se pravo na primanje WTC-a provjerava prema dohotku obitelji. U ovom istraživanju će se originalni WTC modificirati tako da će u prvoj reformi ta naknada biti provjeravana prema dohotku obitelji (naziv naknade/ reforme WTC-FAM), dok će u drugoj

[26] Budući da su miCROmodA i EUROMOD statički mikrosimulacijski modeli u kojima se pretpostavlja da reforme poreza i socijalnih naknada ne utječu na ponašanje pojedinaca na tržištu rada, valja napomenuti kako se u ovom poglavlju radi o statičkim procjenama poticaja za rad. Nadalje, utjecaj odabranih politika za povećanje isplativosti rada na ponudu rada parova u Hrvatskoj analizirao se u radu Bezeredi i sur. (2019).

[27] Više o spomenutim politikama vidjeti u Euromod izvještajima za UK (De Agostini, 2017) i Slovačku (Gabik i Paur, 2017).

reformi biti provjeravana s obzirom na dohodak pojedinaca (naziv naknade/ reforme WTC-IND). U trećoj reformi ETC se provjerava s obzirom na dohodak pojedinaca (naziv naknade/ reforme ETC-IND), kao i u svom originalnom obliku. Sve tri spomenute naknade mogu primati osobe od 18 do 65 godina, uz uvjet da rade barem tri mjeseca u kojima su zaradile barem tri minimalne plaće.

U smislu reforme WTC-FAM obitelj čine supružnici i njihova djeca do 18 godina koja su u sustavu obrazovanja ili djeca do 16 godina ako se više ne školuju. Iznos naknade ovisi o dohotku nakon plaćenih doprinosa za mirovinsko osiguranje. Iznos naknade se dodatno mijenja s obzirom na različite komponente koje ovise o tipu kućanstva (samac, samohrani roditelj, supružnici) i broju mjeseci na godinu provedenih u radnom odnosu. Komponente naknade su prikazane u tablici 5.1., a modificirane su po uzoru na rad Figari (2010), prema kojemu su postavljene tako da su omjeri između različitih komponenti isti kao u izvornoj naknadi koja postoji u UK-u. Veličine komponenti su kalibrirane tako da je ukupan trošak uvođenja naknade jednak 1,5 milijardi kuna, a slična konfiguracija reformi je korištena i u istraživanju koje su proveli Bezeredi i sur. (2019). Preciznije, Bezeredi i sur. (2019) su u hrvatski sustav implementirali naknade koje imaju ista obilježja kao i naknade WTC-FAM i ETC-IND, a jedina razlika je što su u ovom istraživanju te naknade nešto izdašnije po svojim iznosima. Koristeći iznose komponenti iz tablice 5.1. ukupni iznos naknade računa se prema sljedećoj formuli

$$NZN = \max\left[M - \max\left((D-P)s_t;0\right);0\right], \tag{5.1}$$

pri čemu M označava maksimalni iznos naknade koju čini suma odgovarajućih elemenata iz tablice 5.1., D je dohodak promatrane jedinice nakon plaćenih doprinosa za mirovinsko osiguranje, P je prag nakon kojeg se smanjuje maksimalni iznos naknade, a s_t je stopa po kojoj se smanjuje iznos naknade.

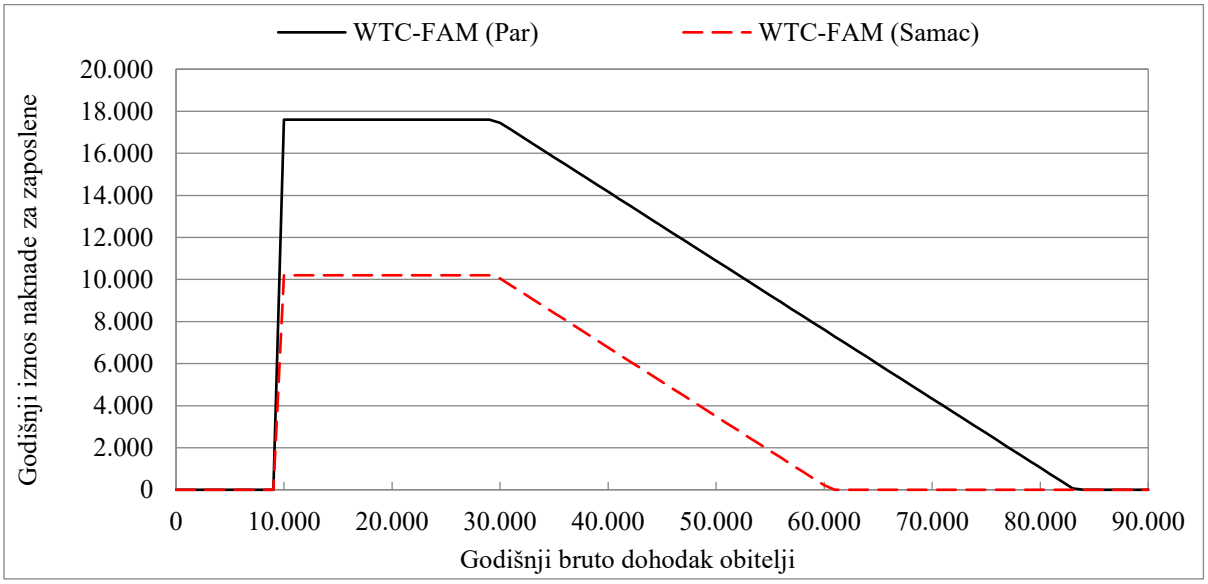
Tablica 5.1. Godišnji iznos elemenata za simulaciju naknada za zaposlene u Hrvatskoj (u kn)

	Reforma (WTC-FAM)	Reforma (WTC-IND)	Reforma (ETC-IND)
Maksimalni iznos naknade (M)	a+b+c+d	a+d	4.551
(a) Osnovni element	7.245	6.993	-
(b) Element za samohranog roditelja	7.431	-	-
(c) Element za parove	7.431	-	-
(d) Element za barem 9 mjeseci rada godišnje	2.995	2.890	-
Prag za smanjenje naknade (P)	23.732	22.906	31.450
Stopa smanjenja (s_t)	0,41	0,41	0,19

Izvor: Autorovi izračuni

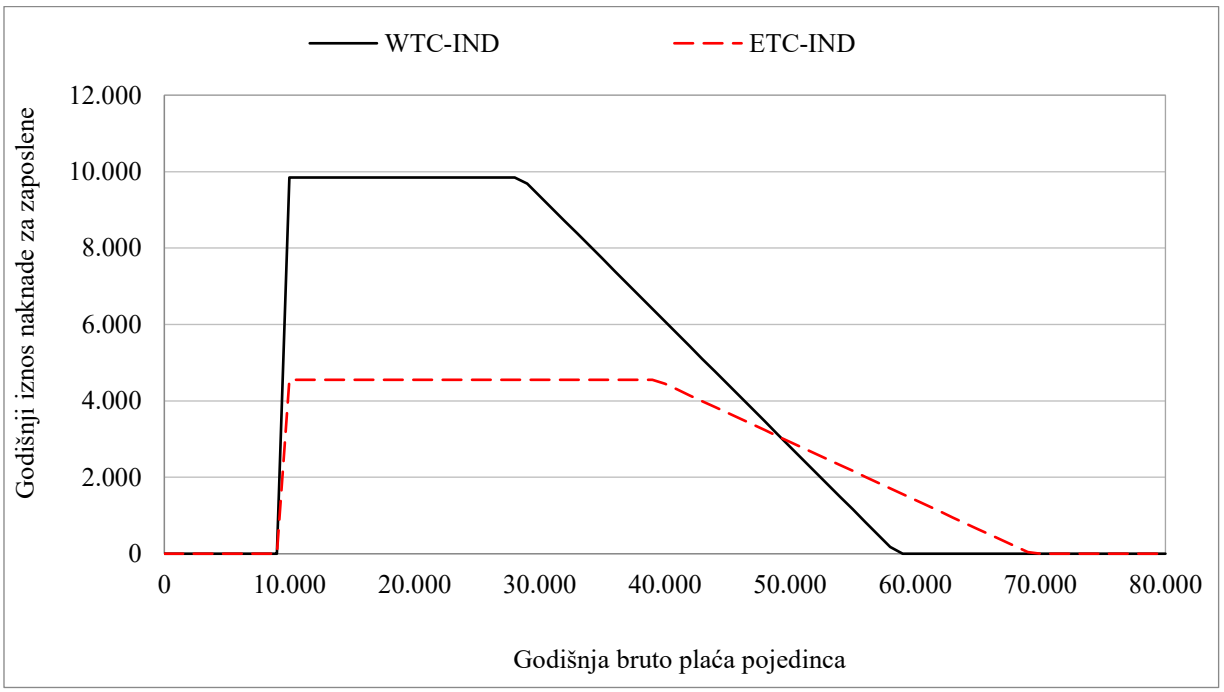
U reformama WTC-IND i ETC-IND jedinica promatranja je pojedinac te se dodjeljuju s obzirom na dohodovni cenzus pojedinca. U taj cenzus ulazi bruto dohodak umanjen za plaćene doprinose za mirovinsko osiguranje. Potencijalni maksimalni iznos naknade WTC-IND izračunava se na temelju dvije komponente: osnovnog elementa i dodatne premije za osobe koje rade barem devet mjeseci na godinu. S druge strane, potencijalni maksimalni iznos naknade ETC-IND ne ovisi ni o tipu obitelji niti predviđa premiju za veći broj mjeseci provedenih u radnom odnosu. U obje reforme, komponente su modelirane kao i u reformi WTC-FAM prema uzoru na rad Figari (2010), a ukupni trošak uvođenja navedenih politika za povećanje isplativosti rada je također 1,5 milijardi kuna. Ukupni iznos naknada (WTC-IND i ETC-IND) računa se na isti način, odnosno prema istoj formuli (5.1), koristeći odgovarajuće komponente iz tablice 5.1. za svaku naknadu.

Radi ilustracije potencijalnih iznosa naknada, na slici 5.1. su prikazani godišnji iznosi naknade WTC-FAM u odnosu na godišnji bruto dohodak obitelji. Kako su komponente (premije) za par i samohranog roditelja iste, valja napomenuti kako su iznosi naknade za par i samohranog roditelja također iste. U ovom primjeru se za samca i par pretpostavlja da rade barem 9 mjeseci, te tako oni dobivaju veće iznose naknade nego u slučaju kada bi radili između 3 i 9 mjeseci. Maksimalni godišnji iznos naknade za par iznosi oko 17.500 kn, dok za samca iznosi oko 10.000 kn, a u oba slučaja isti se dodjeljuje ako je bruto dohodak obitelji između 10 i 30 tisuća kuna godišnje. Pozitivan iznos naknade WTC-FAM za samca se dobiva ako godišnji dohodak ne prelazi 60 tisuća kuna, a parovi primaju naknadu ako im godišnji dohodak ne prelazi granicu od 83 tisuće kuna.



Slika 5.1. Godišnji iznosi naknade za zaposlene WTC-FAM u Hrvatskoj (kn)
Izvor: Autorovi izračuni

Što se tiče naknada provjeravanih s obzirom na dohodak pojedinaca, na slici 5.2. prikazano je kretanje iznosa naknada WTC-IND i ETC-IND u ovisnosti o bruto dohotku pojedinaca. Kod naknade WTC-IND pretpostavlja se da promatrana osoba radi barem 9 mjeseci. Vidi se kako za razliku od naknade ETC-IND, naknada WTC-IND je definirana na način da podrazumijeva veće maksimalne iznose, osobito pri nižim razinama bruto plaće. Međutim, WTC-IND ima manji broj primatelja, primaju je osobe s godišnjim bruto dohotkom do 60.000 kn, dok ETC-IND poprima manje maksimalne iznose i ima veći broj primatelja budući da iščezava kod bruto plaće od 70.000 kn.



Slika 5.2. Godišnji iznosi naknada za zaposlene WTC-IND i ETC-IND u Hrvatskoj (kn)
Izvor: Autorovi izračuni

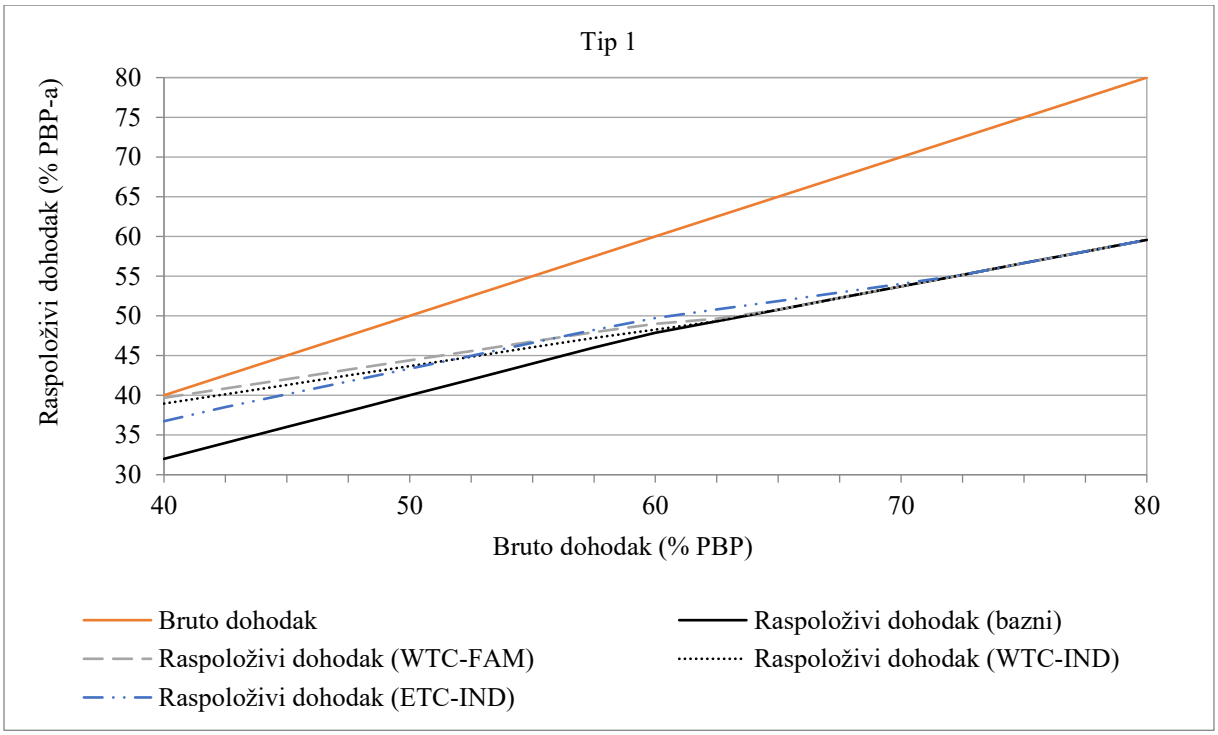
5.1.2. Analiza uvedenih reformi na hipotetskim kućanstvima u Republici Hrvatskoj

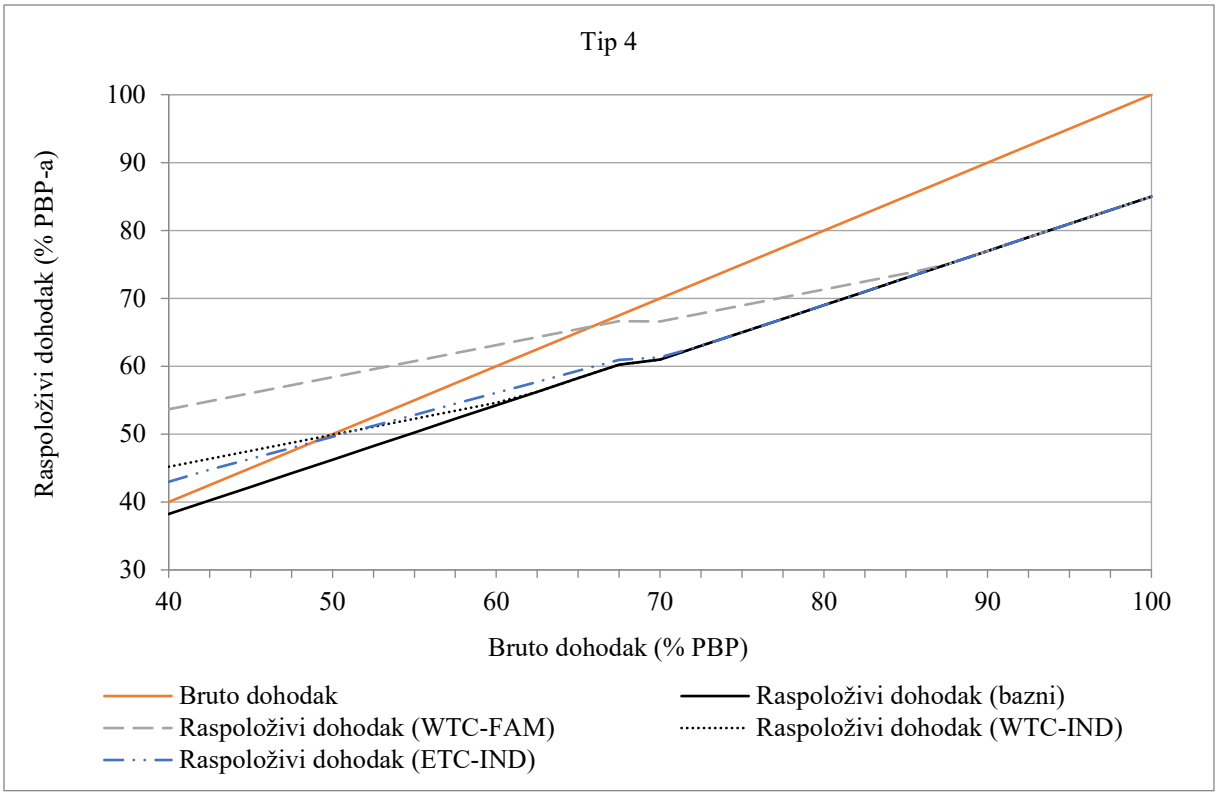
Nakon uvođenja politika za povećanje isplativosti rada u hrvatski sustav poreza i socijalnih naknada, u ovom dijelu se analizira utjecaj njihovog uvođenja na poticaje za rad. Analiza se bazira na hipotetskim kućanstvima, kako bi se što jasnije ilustrirao utjecaj novouvedenih politika za povećanje isplativosti rada na distribuciju dohotka i kretanje PPS-a. Slika 5.3. za različite tipove kućanstva prikazuje raspoloživi dohodak kućanstva pri različitim iznosima bruto dohotka prije i poslije uvedenih reformi. Svi iznosi na slici su izraženi kao postotak prosječne bruto plaće u RH za 2017.

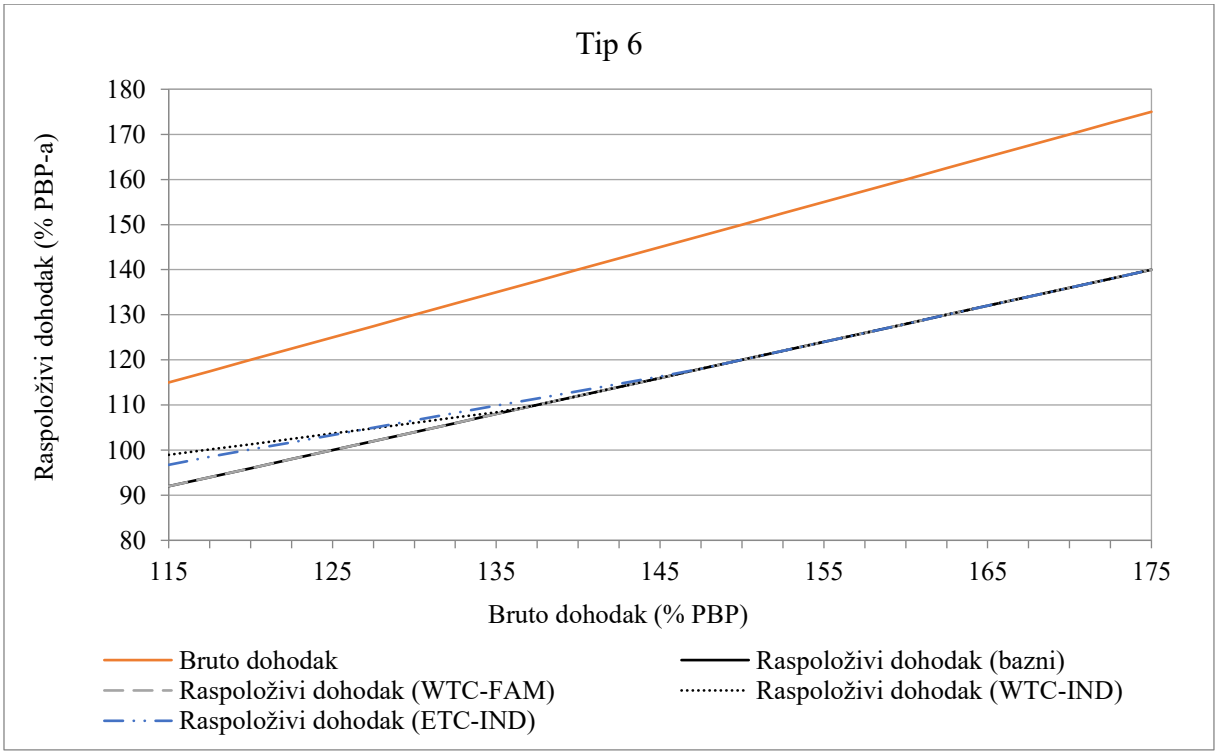
Naknada WTC-FAM ostvaruje najveće iznose kod najnižih plaća za samačka kućanstva i parove s djecom u kojima jedan supružnik radi. Parovi s djecom gdje oba partnera rade ne mogu se

kvalificirati za navedenu naknadu. Razlog tome je što se pravo na primanje naknade WTC-FAM provjerava s obzirom na dohodak obitelji, pa takve obitelji imaju preveliki bruto dohodak da bi se kvalificirale za primanje naknade. Naime, drugi partner već radi i prima 75% PBP-a, dok najmanja plaća prvog partnera može iznositi 40% PBP-a, što daje ukupni iznos od 115% PBP-a, koji je već prevelik da bi se dobivala WTC-FAM naknada. Kako je WTC-FAM orijentirana na primanja obitelji, njeno postojanje najviše povećava raspoloživi dohodak parova s djecom gdje ne radi nijedan supružnik, a ujedno u tom slučaju i njezino primanje najkasnije iščezava.

S druge strane individualna naknada ETC-IND poprima najmanje iznose kod najnižih primanja (od 40 do 50% PBP-a), no s povećanjem primanja ta naknada najdulje traje kod samačkih kućanstava i kod parova s djecom gdje su oba zaposlena. Uspoređuju li se dvije individualne naknade, WTC-IND i ETC-IND, vidljivo je kako naknada WTC-IND poprima veće vrijednosti kada se promatrana osoba zapošljava na bruto plaću u iznosu od 40 do 50% PBP-a, dok je za veće iznose bruto plaće ta naknada manja od ETC-IND i prije iščezava što je vidljivo i iz krivulja raspoloživog dohotka.



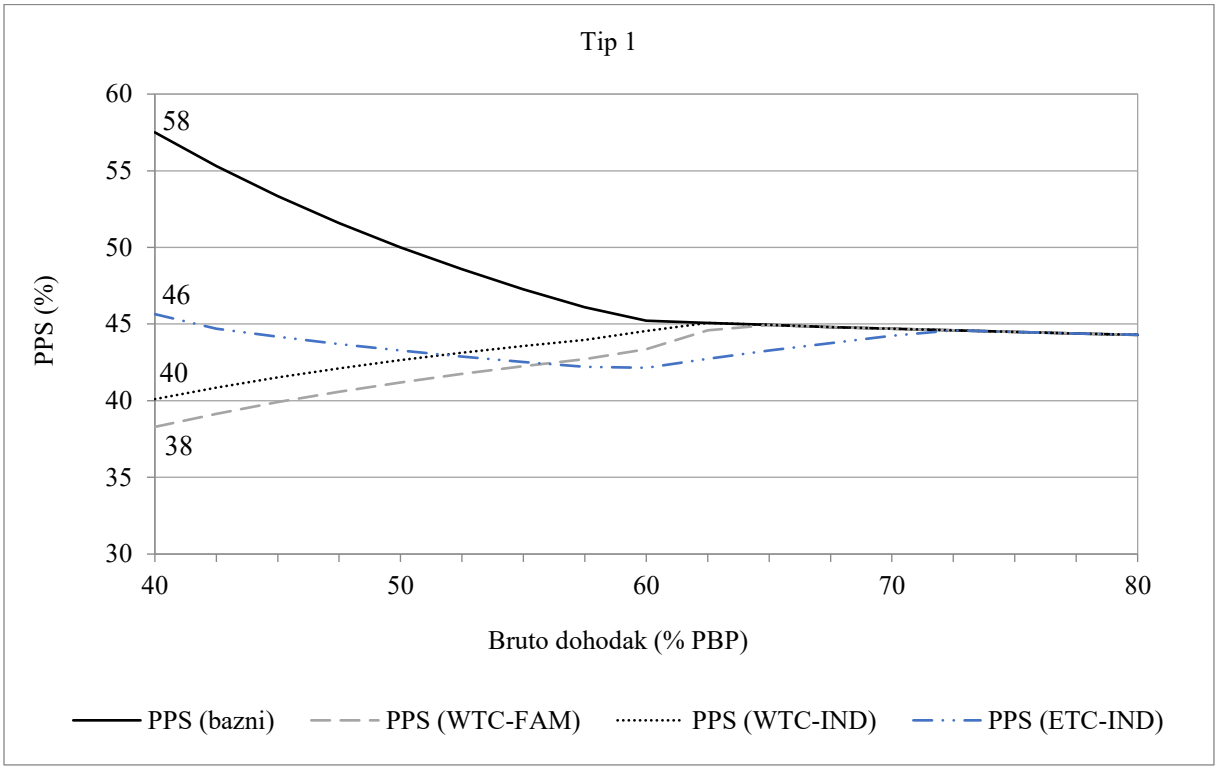


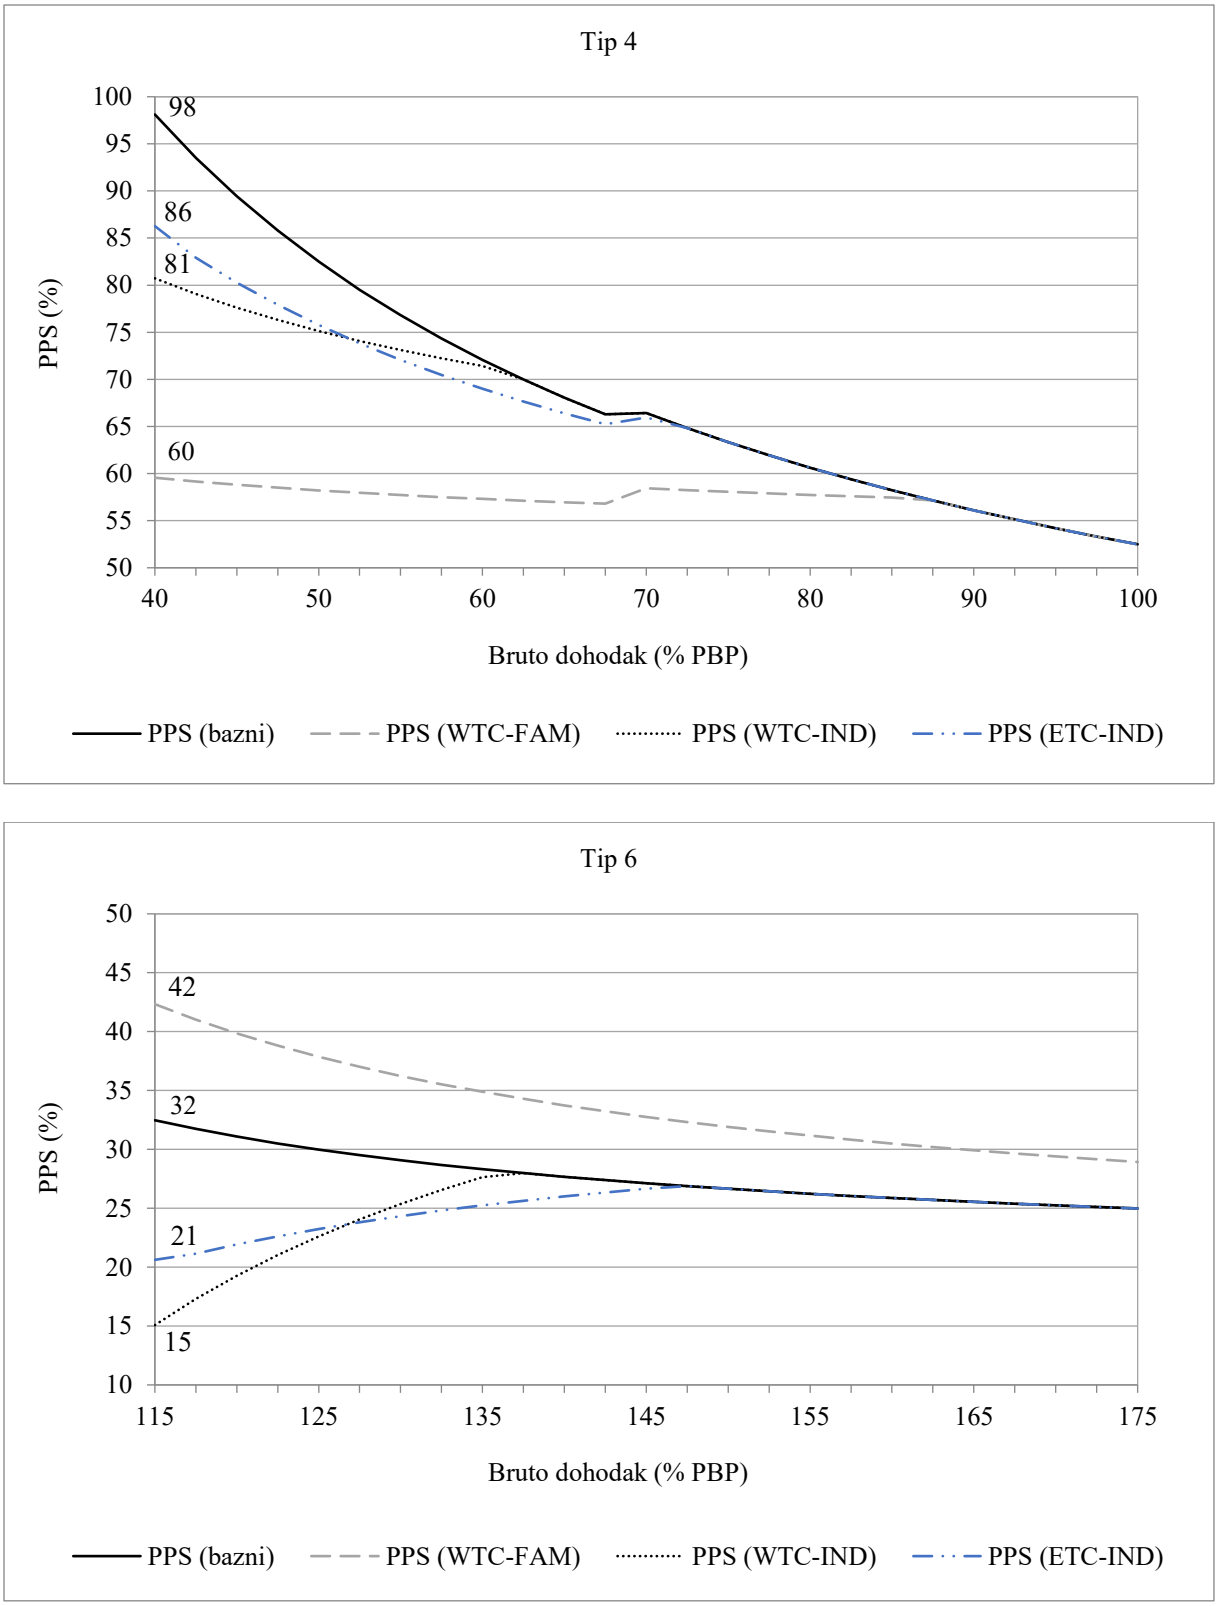


Slika 5.3. Raspoloživi dohodak različitih tipova kućanstava s obzirom na uvedene politike za povećanje isplativosti rada u Hrvatskoj
Izvor: Autorovi izračuni koristeći miCROmodA

Nastavno na analizu izdašnosti naknada i krivulja proračunskih ograničenja, slika 5.4. za iste tipove kućanstava ilustrira obrazac PPS-a prema visini bruto plaće za tri različite reforme u

kojima su uvedene naknade za zaposlene i uspoređuje ih s originalnim (osnovnim) sustavom poreza i socijalnih naknada. Kako uvođenje politika za povećanje isplativosti rada ima za cilj povećanje financijskih poticaja za rad osoba s nižim primanjima, analizira se kako svaka pojedina naknada utječe na PPS. Iz slike je vidljivo kako gotovo u svim scenarijima implementirane politike smanjuju PPS. Iznimka je naknada WTC-FAM kod parova s djecom s oba odrasla zaposlena člana (tip 6), gdje je došlo do povećanja PPS-a. Razlog povećanja PPS-a je taj što se WTC-FAM prima s obzirom na dohodak obitelji, te se u slučaju zaposlenja drugog člana gubi pravo na primanje naknade. Naime, u spomenutom kućanstvu jedan član već radi za bruto plaću 75% PBP-a i u slučaju kada bi drugi član ostao izvan rada to kućanstvo ima pravo na naknadu WTC-FAM; međutim, zaposlenjem drugog odraslog člana na iznos od 40% PBP-a ta naknada se već tada gubi što rezultira povećanjem PPS-a za 10 postotnih bodova. S druge strane, u istom kućanstvu, naknade orijentirane na pojedince, kod zaposlenja drugog odraslog člana na minimalnu plaću, smanjuju PPS i to naknada WTC-IND za 17 i naknada ETC-IND za 10 postotnih bodova. Navedeno potvrđuje činjenicu kako naknade čije dobivanje ovisi o dohotku obitelji imaju negativan utjecaj na zapošljavanje drugog odraslog člana, što je poznati zaključak iz literature.





Slika 5.4. Distribucija PPS-a za različite tipove kućanstava s obzirom na uvedene politike za povećanje isplativosti rada u Hrvatskoj

Napomena: Na slici je izražen iznos PPS-a u slučaju zaposlenja promatrane osobe uz plaću koja iznosi 40% PBP-a.

Izvor: Autorovi izračuni koristeći miCROmodA

Kod kućanstva tipa 4 naknada WTC-FAM najviše smanjuje PPS, što znači da u takvim kućanstvima spomenuta naknada ima najbolji utjecaj na poticanje zapošljavanja. Preciznije, kod zaposlenja prve odrasle osobe na 40% PBP-a uvođenje naknade WTC-FAM smanjuje PPS za gotovo 40 postotnih bodova (PPS u originalnom sustavu iznosi 98%, dok bi se uvođenjem naknade WTC-FAM PPS smanjio na 59%). Naknade orijentirane na pojedince također smanjuju PPS, ali njihov utjecaj je dosta slabiji. Tako kod zaposlenja prve odrasle osobe na 40% PBP-a uvođenje naknade WTC-IND smanjuje PPS za 12 postotnih bodova, dok ga uvođenje naknade ETC-IND smanjuje za oko 17 postotna boda.

Analizirajući zapošljavanje samaca (tip 1) na minimalnu bruto plaću, u odnosu na osnovni scenarij gdje PPS iznosi 57%, naknada WTC-FAM smanjuje stopu PPS-a za 19 postotnih bodova, dok je naknade WTC-IND i ETC-IND redom smanjuju za 17 i 12 postotnih bodova. Iako naknada ETC-IND kod minimalne plaće ima najslabiji utjecaj na smanjenje PPS-a, njezino djelovanje na smanjenje PPS-a najdulje traje, do razine od oko 70% PBP-a.

5.1.3. Analiza utjecaja uvedenih reformi na siromaštvo i raspodjelu dohotka u Republici Hrvatskoj

U zemljama južne Europe politike koje su orijentirane na pomoć siromašnim radnicima, kao što su naknade za zaposlene, često se koriste i kao sredstvo pomoći za značajan dio siromašne radne populacije (Figari, 2010).[28] U ovom dijelu koristeći stvarne podatke analiziraju se distributivni učinci uvedenih naknada za zaposlene, odnosno analizira se njihov utjecaj na stopu siromaštva cjelokupne populacije i zaposlenih pojedinaca posebno.

Najprije se analizira distribucija novouvedenih naknada među kućanstvima, odnosno postotak kućanstava primatelja naknada, kao i prosječni i maksimalni iznosi svake naknade. Rezultati su prikazani u tablici 5.2. iz koje je vidljivo kako naknada WTC-FAM pruža najveće maksimalne (1.467 kn) i prosječne (466 kn) iznose, ali je prima najmanji broj kućanstava, njih 298 tisuća, što čini 20% svih kućanstava u Hrvatskoj. U Hrvatskoj postoji određeni broj složenih kućanstava,[29] pa postoje kućanstva u kojima više osoba može primati određenu naknadu. Tako u 17% kućanstava naknadu WTC-FAM prima samo jedna osoba, dok je u 3% slučajeva primaju

[28] Naknade za zaposlene smanjuju stopu siromaštva i povećavaju raspoloživi dohodak zaposlenih osoba, te su kao takve orijentirane na siromašnu zaposlenu populaciju i nisu idealan „alat“ ako je cilj politike reducirati siromaštvo cjelokupne populacije (Bargain i Orsini, 2006).

[29] Pod složenim kućanstvima se smatraju više generacijska kućanstva, kućanstva u kojima postoji više od jednog para supružnika ili kućanstva u kojima postoji par supružnika i odrasli samac/samci.

više od jedne osobe u kućanstvu. S druge strane, naknada ETC-IND prosječno iznosi tek 182 kn (njezin maksimalni iznos je 379 kn), međutim, ona je raspoređena na 501 tisuću kućanstava. U 23,5% kućanstava naknadu ETC-IND prima samo jedna osoba, a u 10% kućanstava spomenutu naknadu prima više od jedne osobe u kućanstvu. Naknada WTC-IND je po svojoj distribuciji među kućanstvima između preostale dvije naknade, raspoređena je na 26% kućanstava s prosječnim i maksimalnim iznosom od 336 i 821 kn.

Tablica 5.2. Distribucija uvođenja naknade za zaposlene među kućanstvima u Hrvatskoj, agregatni pokazatelji

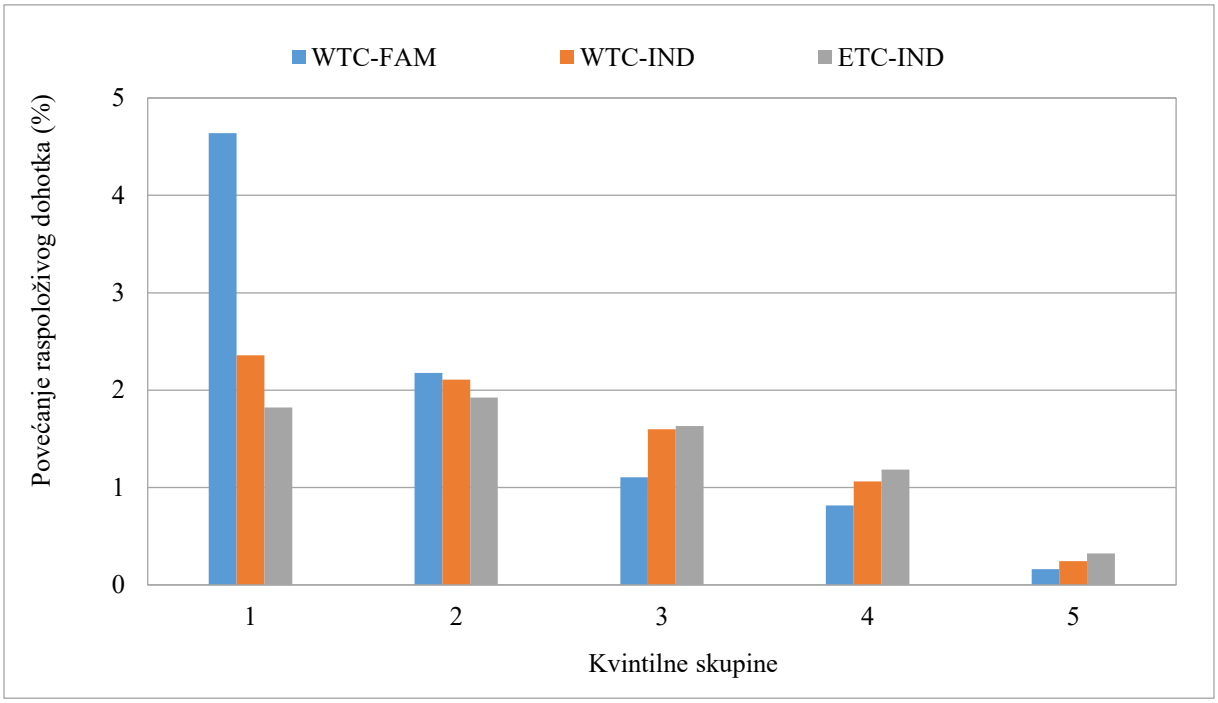
	WTC-FAM	WTC-IND	ETC-IND
Primatelji			
Broj kućanstava u kojima barem jedna jedinica prima naknadu (u tis.)	298	390	501
(% od ukupnog broja kućanstava u populaciji)	20,0	26,2	33,6
Broj kućanstava u kojima točno jedna jedinica prima naknadu (u tis.)	254	297	350
(% od ukupnog broja kućanstava u populaciji)	17,0	19,9	23,5
Broj kućanstava u kojima više od jedne jedinice prima naknadu (u tis.)	45	94	151
(% od ukupnog broja kućanstava u populaciji)	3,0	6,3	10,2
Najviši neto iznos (kn/ mjesečno)	1.473	824	379
Prosječni neto iznos (kn/ mjesečno)	464	334	182

Izvor: Autorovi izračuni koristeći miCROmodA

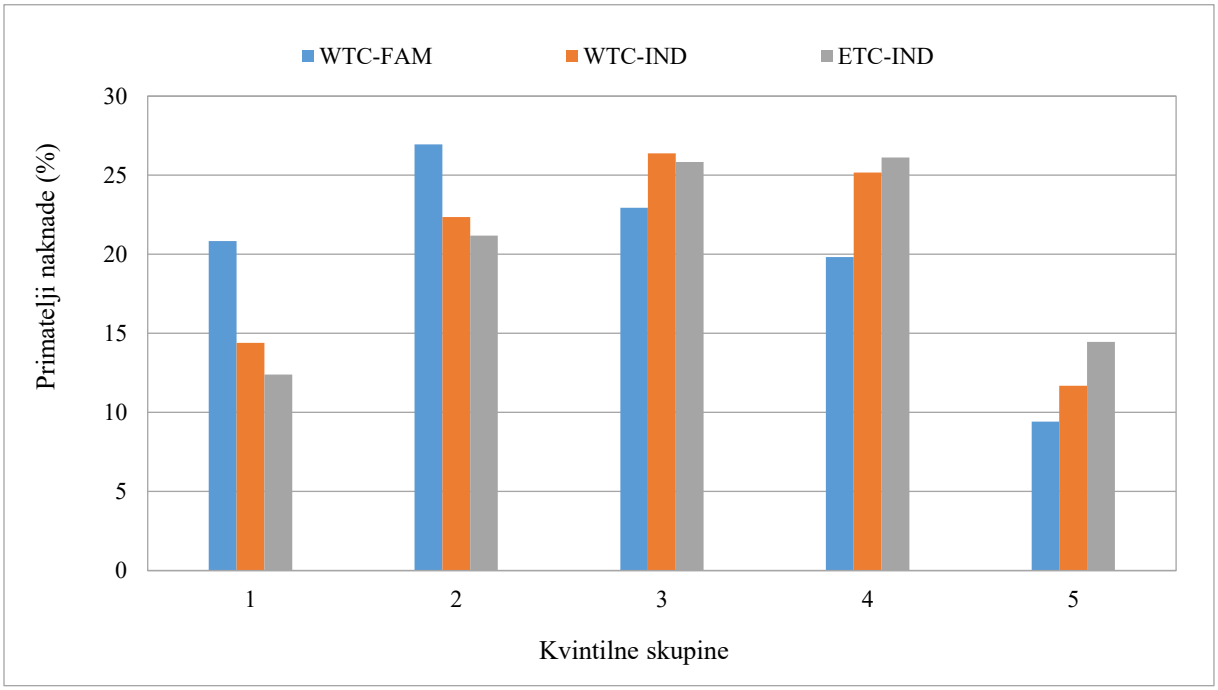
Što se tiče analize utjecaja uvođenja naknade za zaposlene na dohodak kućanstava pojedinih kvintilnih skupina, slika 5.5. prikazuje postotno povećanje raspoloživog dohotka kućanstva nastalo uvođenjem svake odabrane naknade za zaposlene, a slika 5.6. prikazuje primatelje naknade za zaposlene prema kvintilnim skupinama kućanstava. Kvintilne skupine određene su na temelju ekvivalentnog raspoloživog dohotka kućanstava koristeći modificiranu OECD ljestvicu. Pokazalo se da naknada WTC-FAM ima najveći utjecaj na povećanje raspoloživog dohotka prve i druge kvintilne skupine, povećava ih za 4,6 i 2,2%. Za razliku od naknada WTC-IND i ETC-IND, naknada WTC-FAM je raspoređena na manji broj kućanstava, te s obzirom da je provjeravana s obzirom na dohodak obitelji, više je koncentrirana na kućanstva iz nižih kvintilnih skupina. Navedeno potvrđuje i slika 5.6. koji prikazuje kako se u prvoj i drugoj kvintilnoj skupini ukupno nalazi 47,8% primatelja naknade WTC-FAM, 36,8% primatelja naknade WTC-IND, te 33,6% primatelja naknade ETC-IND.

S druge strane, naknade WTC-IND i ETC-IND imaju manji utjecaj na povećanje raspoloživog dohotka prve i druge kvintilne skupine; WTC-IND redom povećava raspoloživi dohodak za 2,4 i 2,1%, a ETC-IND za 1,8 i 1,9%. Razlog tome je što su naknade WTC-IND i ETC-IND raspoređene su na veći broj kućanstva, provjeravane su s obzirom na dohodak pojedinaca, i tako

postoji veća vjerojatnost da ih mogu dobivati nisko plaćeni ljudi iz kućanstava u višim kvintilnim skupinama, pa stoga imaju i veći utjecaj na povećanje raspoloživog dohotka kućanstva među višim kvintilnim skupinama. Također, slika 5.6. prikazuje kako zadnje tri kvintilne skupine imaju veći broj primatelja naknada ETC-IND i WTC-IND nego naknade WTC-FAM.



Slika 5.5. Povećanje raspoloživog dohotka kućanstva u Hrvatskoj u odnosu na osnovni scenarij (%)
Izvor: Autorovi izračuni koristeći miCROmodA



Slika 5.6. Primatelji naknade za zaposlene prema kvintilnim skupinama kućanstava u Hrvatskoj
Izvor: Autorovi izračuni koristeći miCROmodA

Dodatno, analizira se još jedan cilj distribucijske politike, a to je utjecaj novouvedenih reformi na smanjenje stope siromaštva. Siromaštvo se računa prema standardnoj granici siromaštva od 60% medijana ekvivalentnog raspoloživog dohotka kućanstva te dodatno i prema granici od 40% medijana. Granice siromaštva su izračunate na temelju osnovnog scenarija. Stope siromaštva za osnovni i reformske scenarije prikazane su u tablici 5.3. (za cjelokupnu populaciju) i u tablici 5.4. (posebno za zaposlenu populaciju).[30]

Naknada WTC-FAM se dobiva s obzirom na dohodak obitelji i tako uglavnom obuhvaća najsiromašnije obitelji,[31] poprima najveće maksimalne i prosječne iznose, raspoređena je na manji broj kućanstava od ostalih naknada koje su provjeravane s obzirom na dohodak pojedinaca, te posljedično i najviše reducira stopu siromaštva. Na granici siromaštva od 60% medijana, stopa siromaštva iznosi 20,4%, a uvođenjem naknade WTC-FAM postiže se smanjenje stope za 8,4% pa tada stopa siromaštva iznosi 18,6%. Navedeno je rezultiralo izlaskom oko 21 tisuća kućanstava iznad granice siromaštva.

Što se tiče naknada koje su provjeravane s obzirom na dohodak pojedinaca pokazalo se kako one imaju manji utjecaj na smanjenje stope siromaštva, a efikasnijom se pokazala naknada WTC-IND koja na granici od 60% smanjuje stopu siromaštva za 5,5%, dok je naknada ETC-IND smanjuje za 4,8%. To je očekivani rezultat s obzirom da je naknada ETC-IND raspoređena na veći broj primatelja, odnosno ima širi dohodovni cenzus, a samim time poprima manje iznose po pojedincu, što rezultira manjim povećanjem raspoloživog dohotka najsiromašnijih kućanstava. Uvođenjem naknade WTC-IND oko 12 tisuća kućanstava je prešlo izvan linije siromaštva, dok ih je oko 11 tisuća izašlo uvođenjem nakade ETC-IND. Dakle, na slučaju Hrvatske se potvrdila hipoteza **H3** koja tvrdi da je naknada za zaposlene uz provjeru dohotka obitelji efikasnija u smanjenju stope siromaštva nego naknade za zaposlene uz provjeru dohotka pojedinca.

[30] Stopa siromaštva mjeri postotak osoba čiji je ekvivalentan raspoloživi dohodak ispod određene granice siromaštva.

[31] Figari (2010) navodi kako se u određenim slučajevima kod višegeneracijskih kućanstava može dogoditi da naknade provjeravane na obiteljski dohodak mogu pripasti i „bogatijim“ kućanstvima u slučaju kada baka ili djed imaju relativno visoke vlastite prihode (mirovina, itd.). Tako, kod zemalja s većim brojem višegeneracijskih kućanstava gdje starije osobe imaju relativno visoke prihode može se dogoditi da su individualno orijentirane naknade efikasnije u smanjenju stope siromaštva od obiteljski orijentiranih naknada. Individualne naknade može primati veći broj ljudi u kućanstvu te se tako poboljšavaju redistribucijski učinci, a s druge strane obiteljski orijentirane naknade mogu u spomenutim slučajevima pripasti kućanstvima u koja spadaju u najviše decilne skupine.

Tablica 5.3. Utjecaj uvođenja naknade na stopu siromaštva u Hrvatskoj

	Osnovni scenarij	WTC-FAM	WTC-IND	ETC-IND
Stopa siromaštva – **60% medijana**, u %	20,4	18,6	19,3	19,5
Promjene stope siromaštva u odnosu na osnovni scenarij, u %		-8,4	-5,0	-4,3
Broj kućanstava ispod razine siromaštva – 60% medijana (u tis.)	347	326	335	336
Stopa siromaštva – **40% medijana**, u %	8,5	7,9	8,1	8,2
Promjene stope siromaštva u odnosu na osnovni scenarij, u %		-7,4	-4,1	-3,3
Broj kućanstava ispod razine siromaštva – 40% medijana (u tis.)	148	140	143	144

Napomena: Pragovi linije siromaštva računani su na temelju osnovnog scenarija
Izvor: Autorovi izračuni koristeći miCROmodA

Promatrajući sve tri naknade za zaposlene, smanjenje stope siromaštva intenzivnije je kada je granica siromaštva postavljena na 60% medijalnog raspoloživog ekvivalentnog dohotka kućanstva, nego kada je ta granica postavljena na 40%. Figari (2010) navodi kako se takvi rezultati dobivaju u većini istraživanja, a kao razlog tome Bargain i Orsini (2006) navode što su najsiromašniji među siromašnima uglavnom neaktivne osobe pa na njih ne utječu novouvedene reforme koje su orijentirane na zaposlene osobe. Suprotni rezultati dobiveni su u istraživanju Figari (2010), gdje se u slučaju Italije i Portugala pokazalo kako je smanjenje stope siromaštva intenzivnije na nižim linijama siromaštva.

Što se tiče populacije zaposlenih (tablica 5.4.), za osobe zaposlene svih 12 mjeseci stopa siromaštva uz granicu od 60% medijana iznosi 4,15%. Uvođenjem naknada za poticanje isplativosti rada siromaštvo se smanjuje gotovo za isti iznos postotnih bodova kao i stopa siromaštva cijele populacije. Međutim, realni utjecaji su puno veći, zbog manjeg udjela siromašnih među zaposlenima nego u slučaju kada se promatra cjelokupna populacija (Figari, 2010). Tako na granici siromaštva od 60% medijana za osobe zaposlene svih 12 mjeseci, WTC-FAM smanjuje stopu siromaštva za 47%, a naknade WTC-IND i ETC-IND je redom smanjuju za 23 i 22%. Uzmu li se u obzir zaposleni koji rade barem pola godine, onda je stopa siromaštva nešto veća i iznosi 5,63%. U tom slučaju na granici od 60% medijana, naknada WTC-FAM smanjuje stopu siromaštva za 37%, dok je naknade WTC-IND i ETC-IND smanjuju svaka za 21%.

Tablica 5.4. Utjecaj uvođenja naknade na stopu siromaštva zaposlenih osoba u Hrvatskoj (u %)

	Osnovni scenarij	WTC-FAM	WTC-IND	ETC-IND
Zaposleni svih 12 mjeseci				
Stopa siromaštva – 60 % medijana, u %	4,15	2,21	3,21	3,39
Promjene stope siromaštva u odnosu na osnovni scenarij, u %		-47	-23	-22
Stopa siromaštva – 40 % medijana, u%	0,56	0,12	0,30	0,31
Promjene stope siromaštva u odnosu na osnovni scenarij, u %		-79	-46	-80
Zaposleni 9 do 12 mjeseci				
Stopa siromaštva – 60 % medijana, u %	4,35	2,44	3,39	3,59
Promjene stope siromaštva u odnosu na osnovni scenarij, u %		-44	-22	-21
Stopa siromaštva – 40 % medijana, u %	0,60	0,14	0,34	0,35
Promjene stope siromaštva u odnosu na osnovni scenarij, u %		-77	-43	-71
Zaposleni 6 do 12 mjeseci				
Stopa siromaštva – 60 % medijana, u %	5,63	3,55	4,46	4,66
Promjene stope siromaštva u odnosu na osnovni scenarij, u %		-37	-21	-21
Stopa siromaštva – 40 % medijana, u %	1,25	0,61	0,86	0,89
Promjene stope siromaštva u odnosu na osnovni scenarij, u %		-51	-32	-42

Izvor: Autorovi izračuni koristeći miCROmodA

5.1.4. Analiza pokazatelja isplativosti rada u Republici Hrvatskoj

U ovom dijelu koristeći stvarne podatke analizira se utjecaj uvođenja politika za povećanje isplativosti rada na financijske poticaje za zapošljavanje. Preciznije, analizira se participacijska porezna stopa koja mjeri financijske poticaje za rad prilikom zapošljavanja neaktivne i nezaposlene populacije na puno radno vrijeme. Prvo se definiraju osobe koje će se promatrati i analizira se njihova struktura. Potom se analizira distribucija novouvedenih politika za povećanje isplativosti rada prema određenim tipovima kućanstava, te se na koncu analizira participacijska porezna stopa.

5.1.4.1. Distribucija naknada za zaposlene prema tipovima fleksibilnih osoba u Republici Hrvatskoj

Tablica 5.5. prikazuje distribuciju naknada za zaposlene za odabrane tipove fleksibilnih osoba. Potencijalni primatelji su osobe koje ispunjavaju uvjete za primatelje naknada za zaposlene. Dakle, potencijalni primatelji su sve osobe između 18 do 65 godina koje su radile barem 3 mjeseca na godinu i zaradile barem tri minimalne plaće na godinu. Svi koji ne zadovoljavaju navedene uvjete nisu potencijalni primatelji. Potencijalni primatelji naknade se dodatno razvrstavaju u tri grupe prema iznosu dobivene naknade: (1) izvan dosega naknade – imaju

preveliki dohodak da bi primali naknadu; (2) maksimalni iznos naknade i (3) pozitivan iznos naknade manji od maksimuma.

Tablica 5.5. Distribucija naknada za zaposlene prema odabranim tipovima fleksibilnih osoba u Hrvatskoj, (u %)

	WTC-FAM	WTC-IND	ETC-IND
Osobe s fleksibilnim supružnikom			
Nije potencijalni primatelj	7,8	23,6	23,8
Potencijalni primatelj	92,2	76,4	76,2
Izvan dosega naknade	73,0	52,4	42,5
Maksimalan iznos naknade	1,7	3,7	1,9
Pozitivan iznos naknade manji od maksimuma	17,6	20,3	31,7
Osobe s nefleksibilnim supružnikom			
Fleksibilni supružnik nije potencijalni primatelj	35,1	35,1	35,1
Fleksibilni supružnik je potencijalni primatelj	64,9	64,9	64,9
Izvan dosega naknade	54,3	40,6	30,7
Maksimalan iznos naknade	0,3	2,9	2,1
Pozitivan iznos naknade manji od maksimuma	10,3	21,4	32,0
Samci u višečlanim kućanstvima			
Nije potencijalni primatelj	28,4	28,4	28,8
Potencijalni primatelj	71,6	71,6	71,2
Izvan dosega naknade	33,6	35,7	26,0
Maksimalan iznos naknade	10,1	9,2	1,7
Pozitivan iznos naknade manji od maksimuma	27,8	26,7	43,5
Samci u jednočlanim kućanstvima			
Nije potencijalni primatelj	26,5	26,5	26,7
Potencijalni primatelj	73,5	73,5	73,3
Izvan dosega naknade	50,9	52,8	43,3
Maksimalan iznos naknade	2,3	2,2	2,3
Pozitivan iznos naknade manji od maksimuma	20,3	18,5	27,8
Samohrani roditelji			
Nije potencijalni primatelj	27,3	27,3	27,3
Potencijalni primatelj	72,7	72,7	72,7
Izvan dosega naknade	22,9	36,7	28,2
Maksimalan iznos naknade	10,2	9,1	5,9
Pozitivan iznos naknade manji od maksimuma	39,7	27,0	38,6

Izvor: Autorovi izračuni

Promatraju li se osobe s fleksibilnim supružnikom, u 92,2% slučajeva jedan ili oba supružnika u obitelji su potencijalni primatelji naknade WTC-FAM. Međutim, oko 1,7% parova s oba fleksibilna supružnika prima maksimalni iznos naknade, 17,6% ih prima pozitivan iznos manji od maksimuma, dok ih je 73% izvan dosega naknade. S druge strane, za naknadu WTC-IND (ETC-IND) se pokazalo kako 76,4% (76,2%) osoba s fleksibilnim supružnikom ispunjava uvjete, 3,7% (1,9%) ih prima maksimalni iznos naknade, 20,3% (31,7%) prima pozitivan iznos manji od maksimuma, a 52,4% (42,5%) ih je izvan dosega naknade.

Kod osoba s nefleksibilnim supružnikom naknada ETC-IND raspoređena je na najveći broj primatelja, 34,1% (32,0% ih prima naknadu manju od maksimuma, 2,1% prima maksimalni

iznos), a slijedi je naknade WTC-IND s 24,3% primatelja (21,4% ih prima naknadu manju od maksimuma, 2,9% prima maksimalni iznos) i WTC-FAM s 10,6% primatelja (10,3% ih prima naknadu manju od maksimuma, a 0,3% prima maksimalni iznos). Razlog najmanjeg udjela primatelja naknade WTC-FAM je iznos dohotka drugog nefleksibilnog primatelja (npr. mirovina), koji ulazi u dohodovni cenzus prilikom izračuna iznosa naknade WTC-FAM. Naknade WTC-IND i ETC-IND u dohodovni cenzus uzimaju samo dohodak promatrane (fleksibilne) osobe, te su tako raspoređene na veći broj primatelja.

Što se tiče samaca u jednočlanim i višečlanim kućanstvima i samohranih roditelja, naknade WTC-FAM i WTC-IND slijede slični obrazac raspodjele među takvim pojedincima, s time da pozitivni iznos naknade WTC-FAM prima nešto više spomenutih fleksibilnih jedinica, što je posebno vidljivo kod samohranih roditelja. Tako maksimalni iznos naknade WTC-FAM (WTC-IND) prima 10,1% (9,2%) samaca u višečlanim kućanstvima, 2,3% (2,2%) samaca u jednočlanim kućanstvima, te 10,2% (9,1%) samohranih roditelja. Pozitivan iznos naknade WTC-FAM (WTC-IND) manji od maksimuma prima 27,8% (26.7%) samaca u višečlanim kućanstvima, 20,3% (18,5%) samaca u jednočlanim kućanstvima i 39,7% (29,0%) samohranih roditelja. Naknada ETC-IND je s nižim iznosima raspoređena na najveći broj fleksibilnih jedinica, a pozitivan iznos naknade manji od maksimuma (maksimalni iznos) prima 43,5% (1,7%) samaca u višečlanim kućanstvima, 27,8% (2,3%) samaca u jednočlanim kućanstvima i 38,6% (5,9%) samohranih roditelja.

5.1.4.2. Distribucija participacijske porezne stope u Republici Hrvatskoj

Participacijska porezna stopa mjeri financijske poticaje za rad prilikom zapošljavanja neaktivne i nezaposlene populacije na puno radno vrijeme. Promatraju se osobe koje su nezaposlene i/ili neaktivne svih 12 mjeseci u godini. Analizira se PPS u *osnovnom scenariju*, odnosno u postojećem sustavu poreza i socijalnih naknada u 2017. Zatim se PPS računa u dodatna *tri reformska scenarija* u kojima su uvedene politike za povećanje isplativosti rada. Metodologija izračuna PPS-a je jednaka kao i u poglavlju 4.3.

Tablica 5.6. daje distribuciju PPS-a za različite tipove obitelji za osnovni scenarij (scenarij prije reformi) i za tri različita scenarija u kojima su uvedene politike za povećanje isplativosti rada. Promatrajući cjelokupnu populaciju osoba izvan rada pokazalo se kako u osnovnom scenariju prosječni PPS iznosi 31,2%, gdje oko 6,2% promatranih osoba ima PPS između 50 i 70%, dok vrlo visok PPS – iznad 70% – ima 2,8% osoba izvan rada. Sve tri uvedene reforme smanjuju

prosječni PPS, a najviše ga smanjuje uvođenje reforme WTC-IND i to za 6,8 postotnih bodova. Uvođenje naknade ETC-IND smanjuje prosječni PPS za 4,6 postotna boda, dok ga naknada WTC-FAM smanjuje za 2,3 postotna boda. Međutim, iako naknada WTC-FAM najslabije djeluje na smanjenje prosječnog PPS-a cjelokupne populacije osoba izvan rada, ta naknada najviše smanjuje udio onih s vrlo visokim PPS-om (većim od 70%), i to za 2 postotna boda (za 71%), dok ga naknade WTC-IND i ETC-IND smanjuju za 1,8 (64%), odnosno za 1,1 (39%) postotna boda.

U hipotetskim primjerima se pokazalo kako su utjecaji uvedenih naknada različiti među određenim skupinama (tipovima obitelji). Njihova heterogenost proizlazi iz različitih konstrukcija svake naknade. Na primjer, naknada WTC-FAM provjerava se prema dohotku obitelji te kao takva ima najveći utjecaj na smanjenje PPS-a kod obitelji u kojoj nitko ne radi, odnosno kod obitelji bez dohotka od plaće, a to su tipovi obitelji s najvećim PPS-om. Primjer takvih obitelji su fleksibilni parovi u kojima ne radi nijedan supružnik, gdje se PPS smanjuje za 12,6 postotna boda (s 39,2% na 26,6%) i samohrani roditelji koji ne rade, gdje se PPS smanjuje za 19,7 postotna boda (s 42,9% na 23,2%). Nadalje, prije uvođenja reforme WTC-FAM, udio parova u kojima nijedan supružnik ne radi i čiji je PPS veći od 50% bio je 25,7%, a uvođenjem spomenute naknade taj udio se smanjio na 9,6%. Kod samohranih roditelja taj efekt je još izraženiji, oko 32,4% populacije u osnovnom scenariju ima PPS veći od 50%, a uvođenjem naknade WTC-FAM udio se smanjuje za 82% i iznosi 5,9%. Suprotno od prethodna dva tipa obitelji, naknada WTC-FAM stvara negativne poticaje za rad parova u kojima jedan supružnik radi, gdje uvođenje naknade WTC-FAM povećava prosječni PPS za 5,9 postotna boda (PPS raste s 29,4% na 35,3%). Naime, ako je jedan od supružnika već zaposlen na relativno nisku plaću, takva obitelj ima pravo na naknadu WTC-FAM. Međutim, zapošljavanjem drugog supružnika dohodak obitelji raste, gubi se pravo na naknadu, te posljedično raste PPS.

Što se tiče analize utjecaja reformi WTC-IND i ETC-IND na prethodno spomenuta tri tipa obitelji i njihove usporedbe s reformom WTC-FAM, dobiva se da za parove u kojima nijedan supružnik ne radi naknada WTC-IND (ETC-IND) smanjuje PPS za 7,3 (4,5) postotna boda, a kod samohranih roditelja za 8,2 (4,4) postotna boda, što je manje nego za naknadu WTC-FAM. Budući da su naknade WTC-IND i ETC-IND provjeravane s obzirom na dohodak pojedinca, za parove s jednim zaposlenim supružnikom one smanjuju PPS za 8,6 i 6,0 postotna boda, što je suprotno od naknade WTC-FAM, koja povećava PPS.

Tablica 5.6. Distribucija participacijske porezne stope nakon uvođenja naknada za zaposlene u Hrvatskoj (u %)

	Prosječni PPS	Distribucija odabranih tipova obitelji prema razredima PPS-a			
		< 30 %	[30%, 50%>	[50%, 70%>	≥ 70%
Ukupno					
Osnovni scenarij	31,2	62,3	28,7	6,2	2,8
WTC-FAM	28,9	57,3	35,5	6,4	0,8
WTC-IND	24,4	70,8	22,3	5,9	1,0
ETC-IND	26,6	71,0	22,0	5,4	1,7
Parovi - fleksibilni supružnik ne radi					
Osnovni scenarij	39,2	47,2	27,1	16,0	9,7
WTC-FAM	26,6	59,7	30,8	7,4	2,2
WTC-IND	31,9	49,6	28,7	17,0	4,7
ETC-IND	34,7	49,4	28,7	16,2	5,7
Parovi - fleksibilni supružnik radi					
Osnovni scenarij	29,4	63,5	33,0	2,8	0,7
WTC-FAM	35,3	33,5	56,5	9,5	0,5
WTC-IND	20,8	79,9	18,0	2,0	0,1
ETC-IND	23,4	80,0	18,0	1,9	0,1
Osobe s nefleksibilnim supružnikom					
Osnovni scenarij	30,9	64,9	27,5	3,4	4,2
WTC-FAM	24,6	72,3	23,7	3,1	1,0
WTC-IND	19,5	77,0	18,1	3,9	1,1
ETC-IND	24,1	76,8	17,1	2,9	3,3
Samci u višečlanim kućanstvima					
Osnovni scenarij	27,4	73,0	22,0	4,6	0,4
WTC-FAM	25,0	75,7	19,9	4,4	0,1
WTC-IND	24,9	75,7	19,4	4,8	0,1
ETC-IND	25,3	76,5	19,0	4,1	0,3
Samci u jednočlanim kućanstvima					
Osnovni scenarij	35,2	45,7	41,1	12,2	1,0
WTC-FAM	32,4	48,8	42,3	7,9	1,0
WTC-IND	32,8	47,7	43,1	8,2	1,0
ETC-IND	33,0	47,6	44,0	8,4	0,0
Samohrani roditelji					
Osnovni scenarij	42,9	45,5	22,1	17,6	14,8
WTC-FAM	23,2	68,9	25,2	3,7	2,2
WTC-IND	34,7	46,6	39,0	12,9	1,6
ETC-IND	38,5	46,2	32,2	11,2	10,4

Izvor: Autorovi izračuni

Promatraju li se samci u višečlanim i jednočlanim kućanstvima, takve osobe nemaju partnera te se, kao i kod naknada WTC-IND i ETC-IND, prilikom izračuna naknade WTC-FAM u obzir uzima samo dohodak promatranih pojedinaca, pa je i djelovanje svih triju naknada na smanjenje PPS-a gotovo jednako. Za samce u jednočlanim kućanstvima u osnovnom scenariju PPS iznosi 35,2%, a udio osoba s PPS-om većim od 50% je 13,2%. Uvođenje naknada WTC-FAM, WTC-IND i ETC-IND redom smanjuje prosječni PPS za 2,8, 2,4 i 2,2 postotna boda, a udio kućanstava s PPS-om većim od 50% se redom smanjuje za 8,9, 9,2 i 8,4 postotna boda. Nadalje,

samci u višečlanim kućanstvima (to su odrasle osobe koje nisu u braku i koje su bez djece, ali ne žive same u kućanstvu) imaju nizak PPS koji iznosi 27,4%, a uvođenje naknada WTC-FAM, WTC-IND i ETC-IND redom smanjuje PPS za 2,4, 2,5 i 2,1 postotna boda. Dodatno, udio osoba s PPS-om većim od 50% je također nizak i u osnovnom scenariju iznosi 5%.

Za osobe s nefleksibilnim supružnikom prilikom izračuna naknade WTC-FAM u obzir se uzima i dohodak nefleksibilnog supružnika (npr. mirovina), dok preostale dvije naknade uzimaju u obzir samo dohodak promatrane osobe pa je tako i smanjenje PPS-a najmanje u scenariju WTC-FAM. Tako PPS u osnovnom scenariju iznosi 30,9%, a uvođenjem naknade WTC-IND smanjuje se PPS za 11,4 postotna boda. Nadalje, naknade ETC-IND i WTC-FAM smanjuju prosječni PPS za 6,8 i 6,3 postotna boda.

Dakle, uspoređujući sva tri tipa uvedenih naknada pokazalo se da je naknada uz provjeru dohotka obitelji efikasnija u smanjenju PPS-a najranjivijih skupina od naknada uz provjeru dohotka pojedinca (potvrđena hipoteza **H2a**). Međutim, naknada uz provjeru dohotka obitelji povećava PPS parova u kojima jedan supružnik radi (potvrđena hipoteza **H2b**). S druge strane, pokazalo se da naknade uz provjeru dohotka pojedinca smanjuju PPS svih podskupina (potvrđena hipoteza **H2c**).

5.2. Učinci uvođenja politika za povećanje isplativosti rada u Republici Sloveniji

U ovom dijelu se analizira uvođenje dva tipa naknada za nezaposlene u slovenski sustav poreza i socijalnih naknada. Kao i u poglavlju 5.1. analiza se provodi na hipotetskim kućanstvima i anketnim podacima.

5.2.1. Definicije reformskih politika u Republici Sloveniji

U slovenski sustav se ugrađuju dvije reforme koje su se u hrvatskom sustavu pokazale kao najučinkovitije u povećanju isplativosti rada, a to su reforme WTC-FAM i WTC-IND. Reforme su definirane na isti način kao i za slučaj Hrvatske (vidjeti poglavlje 5.1.1), a jedina razlika su iznosi komponenata naknada prikazanih u tablici 5.7. Ukupni trošak uvođenja svake od reformi u slovenski sustav iznosi oko 200 milijuna eura. Iznos od 200 milijuna eura dobiva se tako da se pretpostavi da je relativni udio ukupnog troška uvođenja reforme u ukupnom dohotku svih kućanstava u Hrvatskoj i Sloveniji jednak.[32] Na taj način moguće je provesti komparativnu

[32] Trošak naknade od 200 milijuna eura u Sloveniji je dobiven prema spomenutom kriteriju, a sličnost s ukupnim troškom uvođenja naknade u Hrvatskoj koji iznosi 1,5 mlrd. kuna je ispala slučajna.

analizu efikasnosti uvođenja reformi u spomenute dvije zemlje, odnosno analizirati u kojoj je zemlji, uz isti realni trošak, pojedina naknada učinkovitija u povećanju poticaja za rad. Spomenuta komparativna analiza provest će se u poglavlju 5.3.

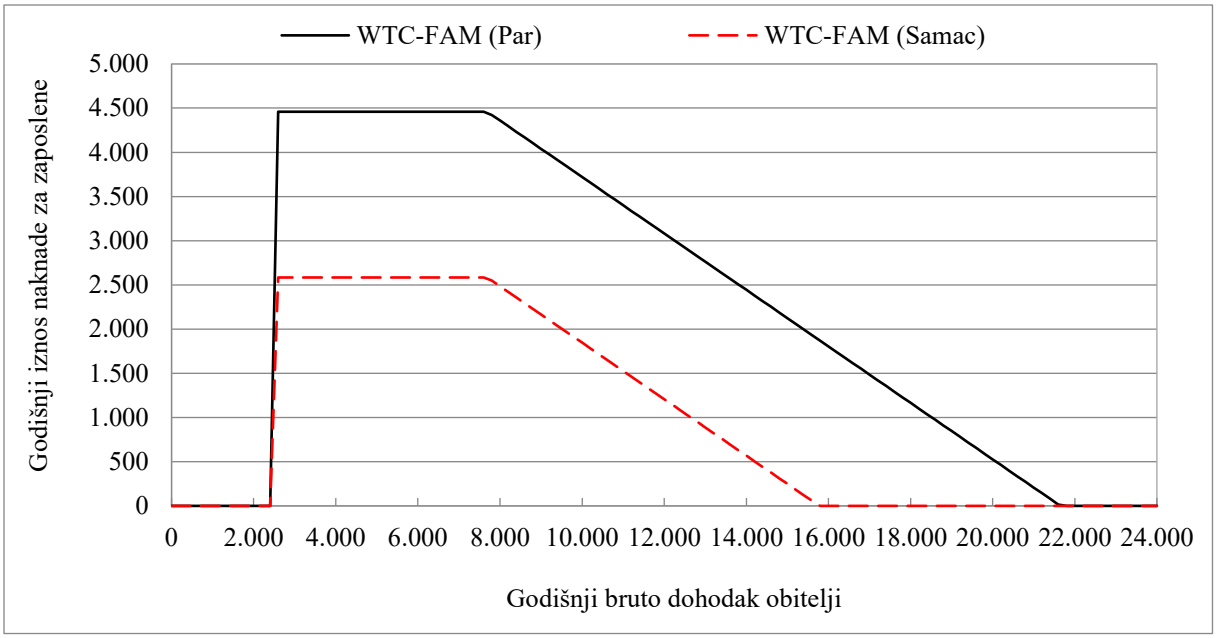
Tablica 5.7. Godišnji iznos elemenata za simulaciju naknada za zaposlene u Sloveniji (u EUR)

	Reforma (WTC-FAM)	Reforma (WTC-IND)
Maksimalni iznos naknade (M)	a+b+c+d	a+d
(a) Osnovni element	1.828	1.755
(b) Element za samohranog roditelja	1.875	-
(c) Element za parove	1.875	-
(d) Element za barem 9 mjeseci rada godišnje	756	725
Prag za smanjenje naknade (P)	5.989	5.749
Stopa smanjenja (s_t)	0,41	0,41

Izvor: Autorovi izračuni

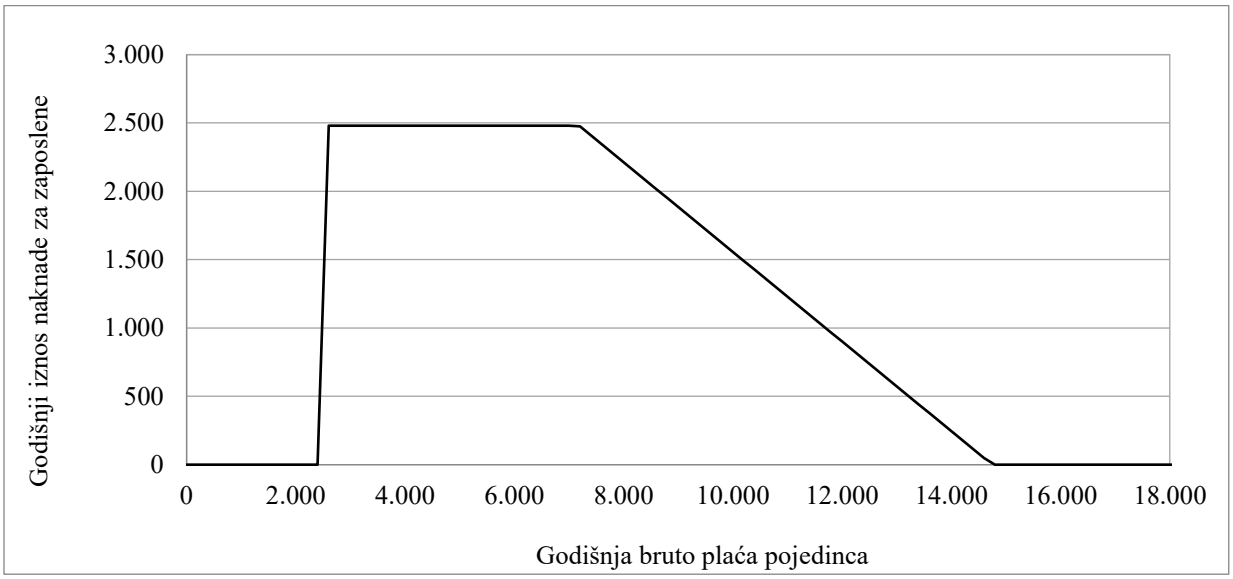
Potencijalni iznos naknade za svaku osobu računa se prema formuli (5.1), a na slici 5.7. je prikazan godišnji iznos naknade WTC-FAM u ovisnosti o godišnjem bruto dohotku obitelji. Analizira se iznos naknade za samca i par/ samohranog roditelja[33], za koje se pretpostavlja da rade barem 9 mjeseci na godinu što im omogućuje da se i komponenta d iz tablice 5.7. uključi u izračun ukupnog iznosa naknade, što nije slučaj kada bi radili između 3 i 9 mjeseci na godinu. Maksimalni godišnji iznos naknade dobivaju obitelji čiji se godišnji bruto dohodak kreće između 2.600 i 7.600 eura, pri čemu se maksimalni iznos za samca iznosi oko 2.600 eura, a za par iznosi oko 4.600 eura. S povećanjem bruto dohotka obitelji iznad 7.600 eura iznosi naknade WTC-FAM za samca i par se postupno smanjuju, dok ne dosegnu vrijednost od nula eura. Tako se samci mogu kvalificirati za primanje naknade sve dok im godišnji bruto dohodak ne prelazi iznos od 15.600 eura, dok je za par taj prag veći i iznosi 21.600 eura.

[33] Elementi b i c u tablici 5.7. su jednaki pa je i iznos naknade WTC-FAM jednaka za samohranog roditelja i par.



Slika 5.7. Godišnji iznosi naknade za zaposlene WTC-FAM u Sloveniji, EUR
Izvor: Autorovi izračuni

S druge strane, kretanje iznosa naknade WTC-IND, koja se dodjeljuje prema dohodovnom cenzusu pojedinca, grafički je prikazano na slici 5.8. Iznosi naknade dani su u ovisnosti o bruto plaći pojedinca, a za promatranu osobu se pretpostavlja da radi barem 9 mjeseci na godinu. Maksimalni iznos naknade iznosi oko 2.500 eura godišnje, a primaju je pojedinci čija se bruto plaća kreće između 2.600 i 7.200 eura na godinu. S porastom bruto plaće pojedinca iznad 7.200 eura potencijalni iznos naknade WTC-IND se smanjuje te na primjer kod bruto plaće od 12.000 eura godišnje iznos naknade za promatranu osobu iznosi oko 1.000 eura, a za sve osobe s godišnjom bruto plaćom većom od 15.000 eura naknada iznosi nula.



Slika 5.8. Godišnji iznosi naknade za zaposlene WTC-IND u Sloveniji, EUR
Izvor: Autorovi izračuni

5.2.2. Analiza uvedenih reformi na hipotetskim kućanstvima u Republici Sloveniji

Analiza utjecaja naknada za povećanje isplativosti rada na poticaje za rad prvo će se provesti za hipotetska kućanstva. Analizira se utjecaj uvedenih reformi WTC-FAM i WTC-IND na distribuciju dohotka i PPS, za tri tipa kućanstva, tipovi 1, 4 i 6. Prvo se za navedene tipove kućanstva analizira utjecaj novouvedenih reformi na raspoloživi dohodak kućanstva pri različitim vrijednostima bruto dohotka (slika 5.9.). Valja spomenuti kako su iznosi na slici izraženi kao postotak prosječne bruto plaće u Sloveniji za 2017.

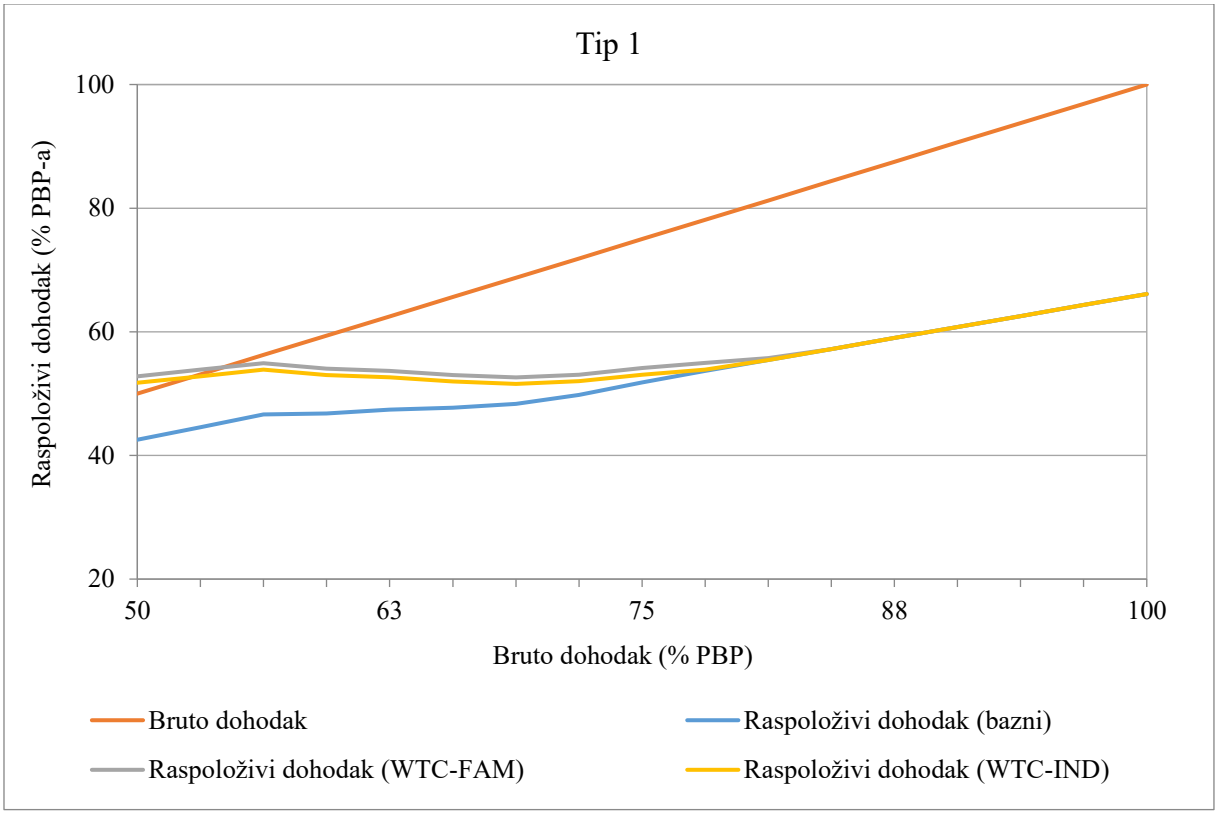
Uspoređujući dvije uvedene naknade, na nižim razinama bruto plaća naknada WTC-FAM povećava raspoloživi dohodak samaca (tip 1) i parova s dvoje djece u kojima se prvi supružnik zapošljava, a drugi ne radi (tip 4) više nego naknada WTC-IND. S druge strane, za par s dvoje djece u kojima prvi supružnik razmatra zaposlenje, a drugi već radi uz bruto plaću od 75% PBP-a (tip 6) samo naknada WTC-IND povećava raspoloživi dohodak kućanstva, dok takvo kućanstvo ne ostvaruje pravo na primanje naknade WTC-FAM.

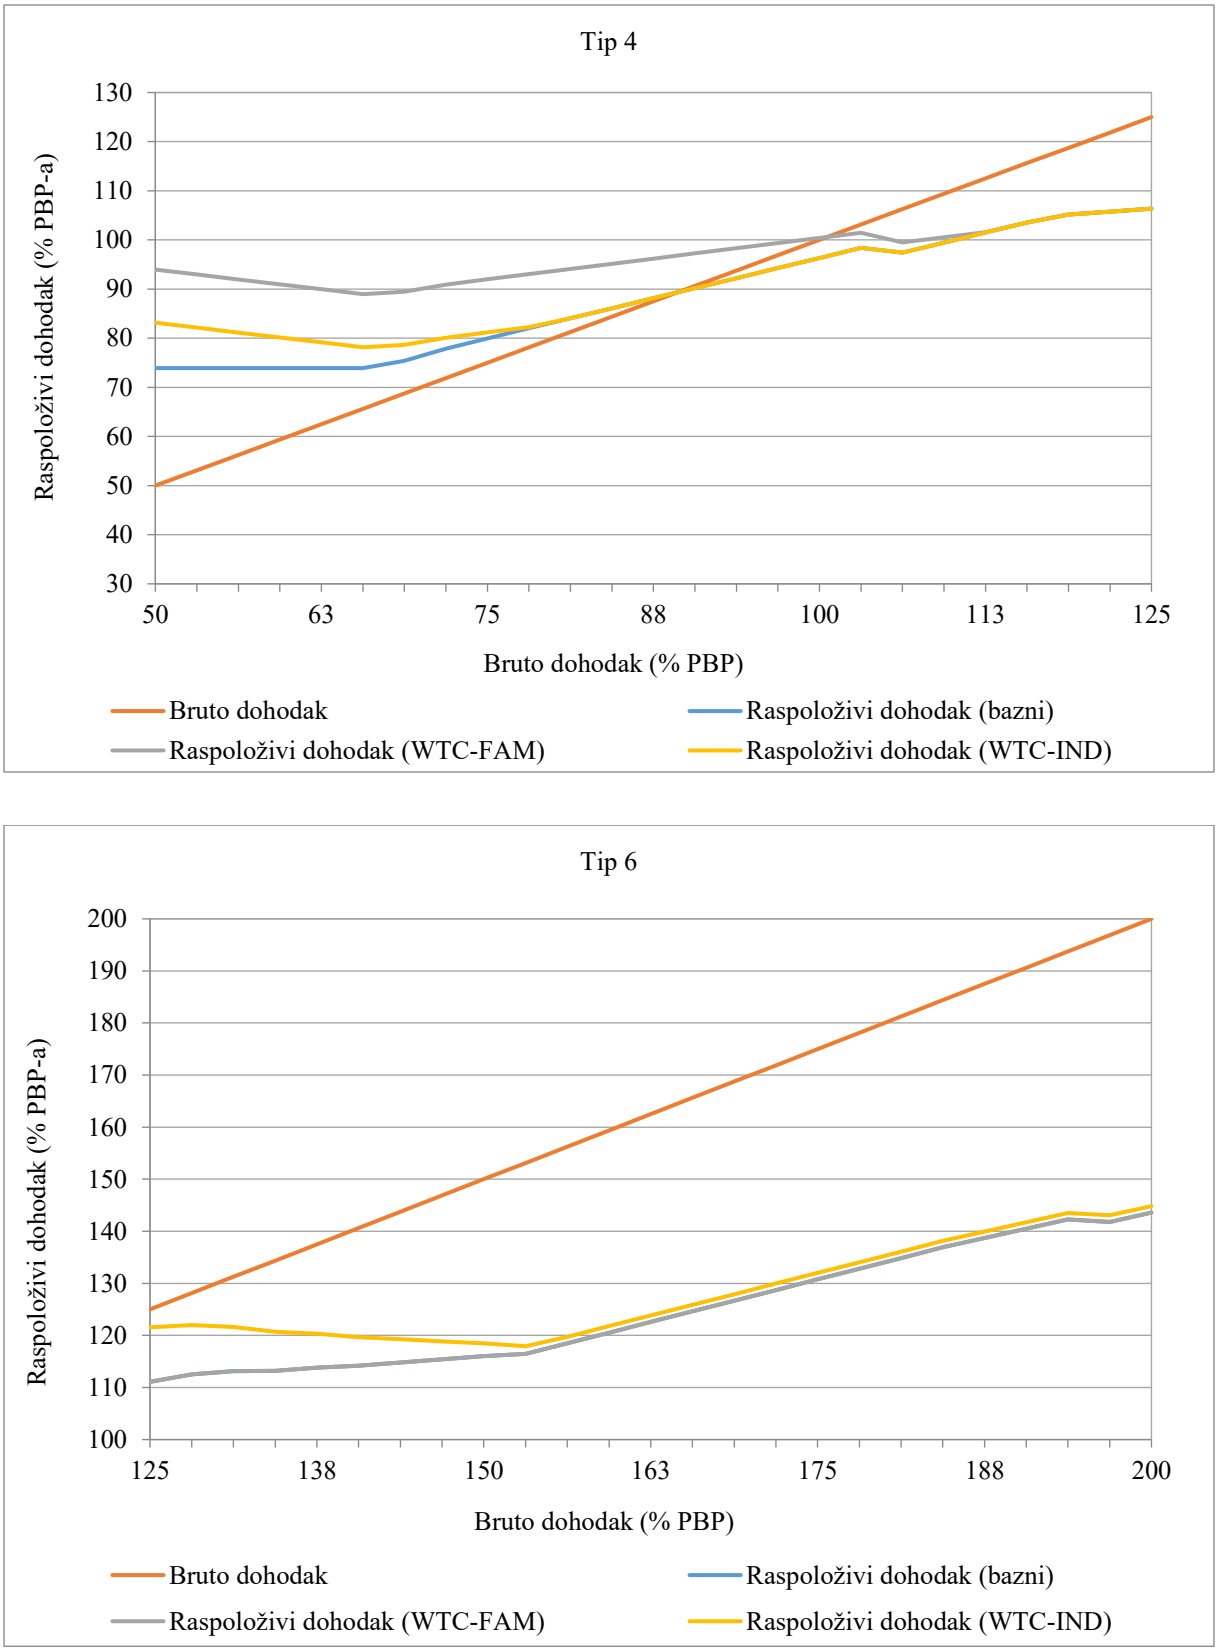
Prilikom zaposlenja samca uz minimalnu bruto plaću, uvođenje naknade WTC-FAM povećava raspoloživi dohodak kućanstva za iznos od 10% PBP-a, dok ga naknada WTC-IND povećava za 9% PBP-a. Drugim riječima, prilikom zaposlenja samca uz minimalnu bruto plaću naknada WTC-FAM iznosi 10% PBP-a, dok naknada WTC-IND iznosi 9% PBP-a. S povećanjem bruto plaće smanjuje se i vrijednost naknade te zaposlenjem uz bruto plaću od 60% PBP-a naknada WTC-FAM iznosi 7% PBP-a, a WTC-IND 6% PBP-a. Naknada se prestaje primati kada bi se samac zaposlio uz bruto plaću od 80% PBP-a. Za sve razine bruto plaće do 80% PBP-a, naknada WTC-FAM je veća od naknade WTC-IND za iznos od 1% PBP-a.

Veća razlika između visine naknada WTC-FAM i WTC-IND je kod kućanstva tipa 4. Zaposlenjem prvog supružnika u tom kućanstvu uz minimalnu bruto plaću naknada WTC-FAM iznosi 20% PBP-a, a naknada WTC-IND 9% PBP-a. Porastom bruto plaće na 75% PBP-a iznosi naknada se smanjuju i WTC-FAM iznosi 12% PBP-a, a WTC-IND 1% PBP-a. Dakle, važna karakteristika za ovaj tip kućanstva je da je naknada WTC-FAM puno izdašnija od naknade WTC-IND, te da se naknada WTC-FAM može primati dok bruto dohodak ne prijeđe iznos od 110% PBP-a, a naknada WTC-IND se može primati ako bruto dohodak ne prijeđe iznos od 80% PBP-a.

Kućanstvo tipa 6 u kojemu su oba odrasla člana zaposlena može primati samo naknadu WTC-IND jer takvo kućanstvo ima previsoki bruto dohodak da bi primali naknadu WTC-FAM.

Naime, u takvom kućanstvu drugi supružnik radi uz bruto plaću od 75% PBP-a, a zaposlenjem prvog supružnika, čak i na minimalnu bruto plaću, prelazi se prag za primanje te naknade. Što se tiče naknade WTC-IND koja se provjerava s obzirom na dohodak pojedinca, na nju ima pravo drugi supružnik u iznosu od 1% PBP-a. Zaposlenjem prvog supružnika uz minimalnu bruto plaću, naknada WTC-IND iznosi 11% PBP-a. Kako raste potencijalna bruto plaća uz koju se zapošljava prvi supružnik, smanjuje se iznos naknade WTC-IND. Za bruto plaću veću od 75% PBP-a, prvi supružnik nema pravo na naknadu WTC-IND. Dakle, za bruto dohotke kućanstva veće od 150% PBP-a, samo drugi supružnik prima naknadu WTC-IND i to u iznosu od oko 1% PBP-a.

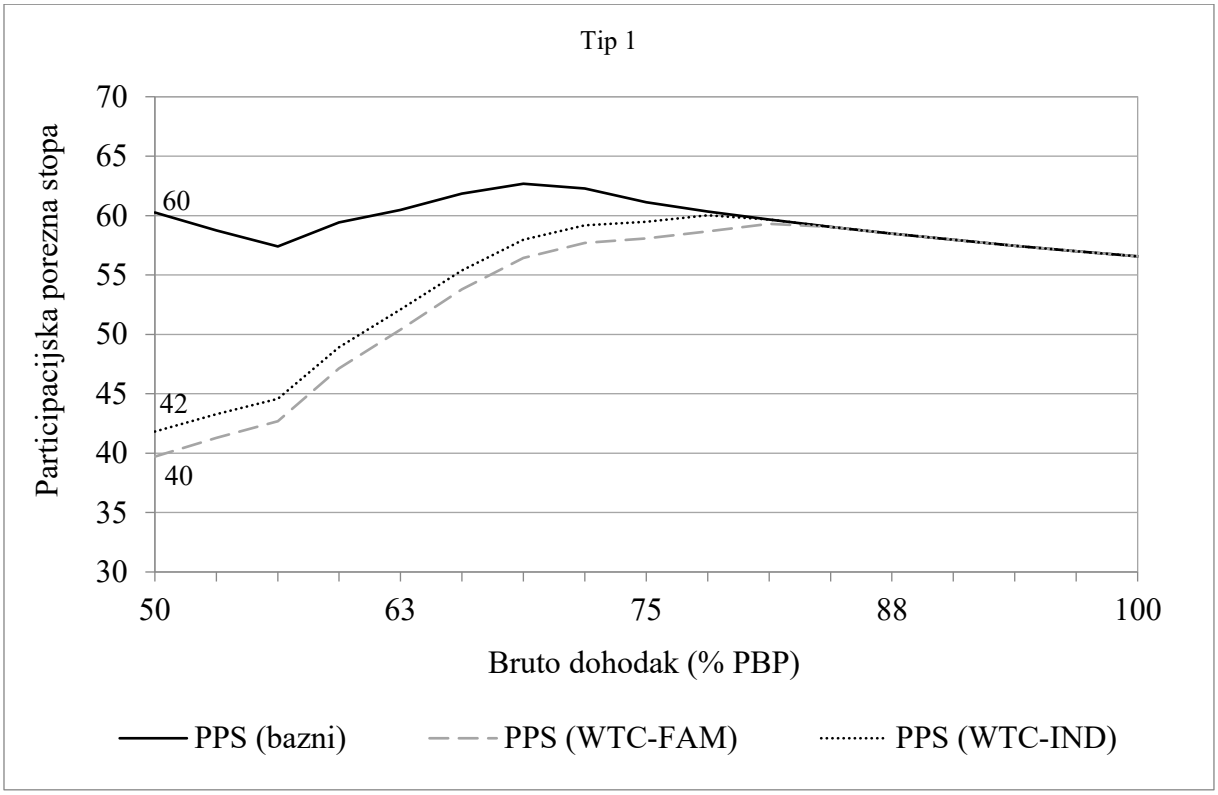


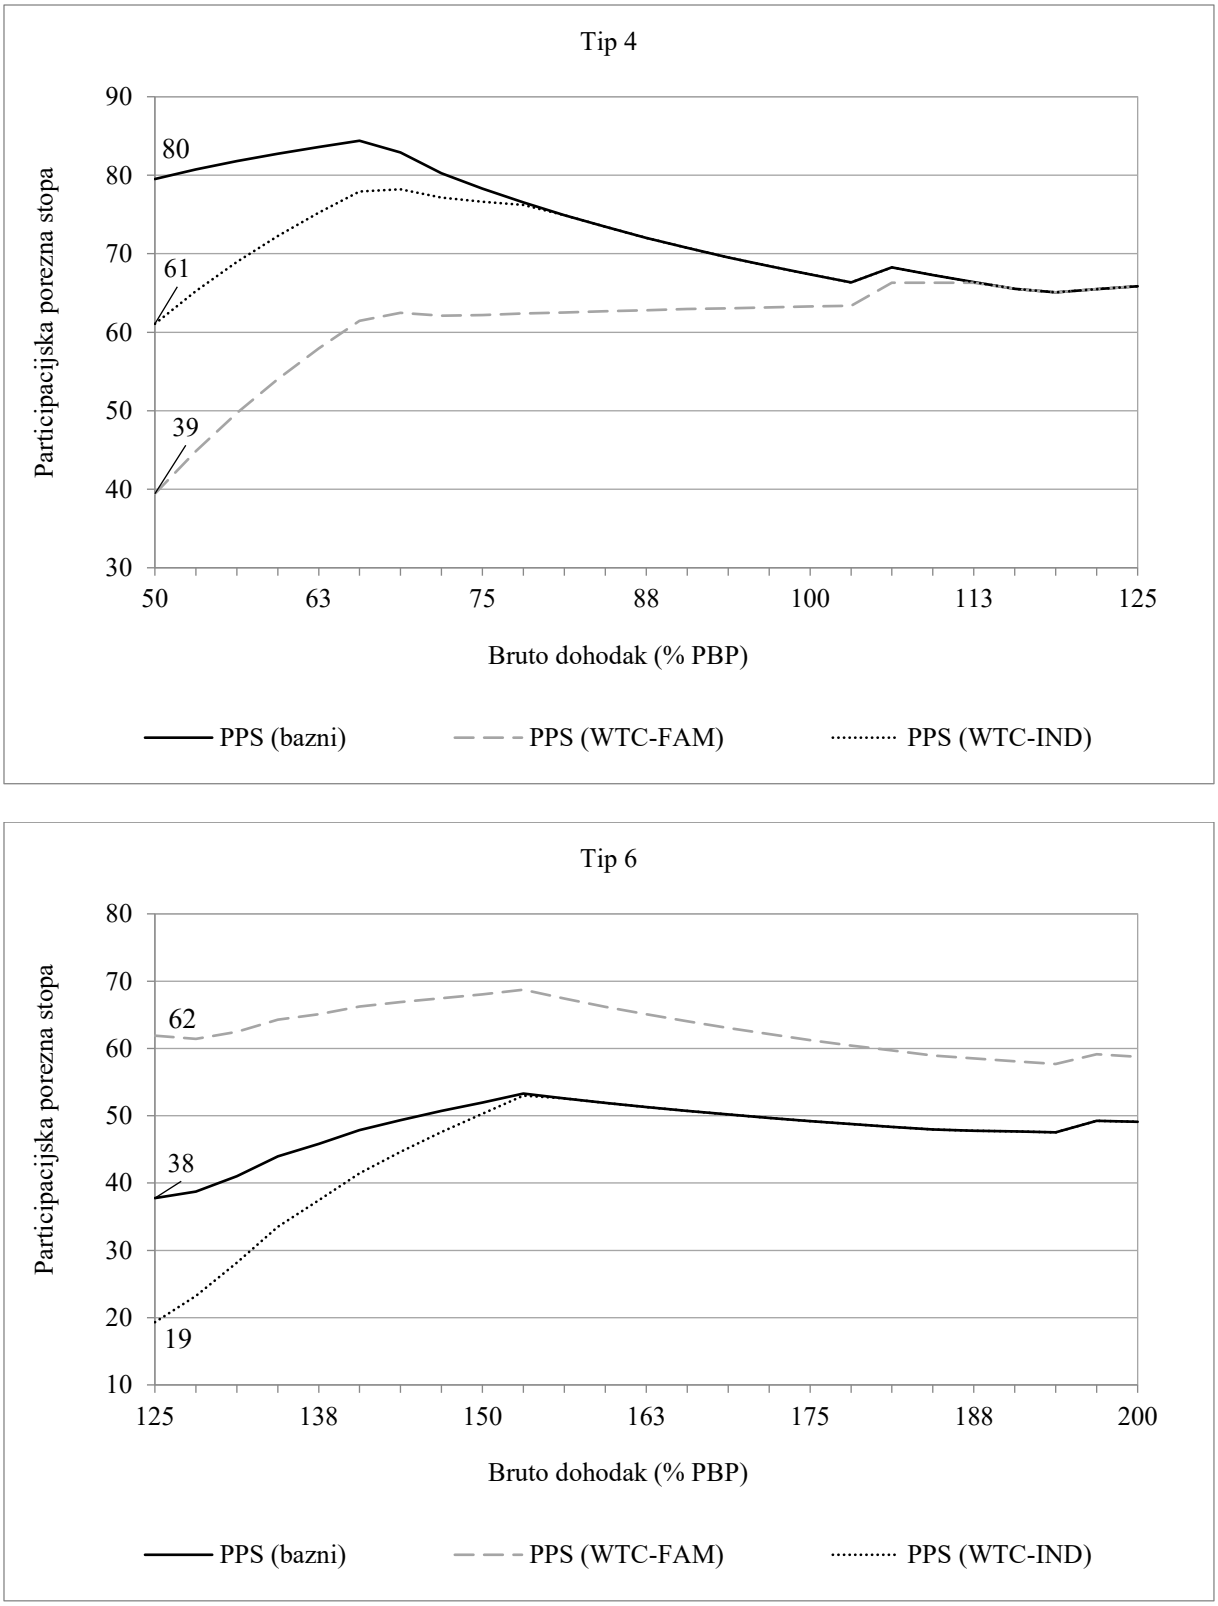


Slika 5.9. Raspoloživi dohodak različitih tipova kućanstava s obzirom na uvedene politike za povećanje isplativosti rada u Sloveniji

Izvor: Autorovi izračuni koristeći Euromod

Nakon analize krivulja raspoloživog dohotka, na slici 5.10. se za iste tipove kućanstva uspoređuje visina PPS-a u stvarnom stanju i u situaciji kada se u slovenski sustav uvode naknade za zaposlene. Glavni cilj uvođenja naknada za zaposlene je povećanje poticaja za rad odnosno smanjenje PPS-a pa se analizira kako pojedine naknade utječu na smanjenje PPS-a. Iz slike je vidljivo kako naknada WTC-FAM smanjuje PPS za kućanstva tipa 1 i tipa 4, dok za kućanstvo tipa 6 ta naknada uzrokuje povećanje PPS-a. Naime, u kućanstvu tipa 6 drugi supružnik već radi uz bruto plaću od 75% PBP-a te kada bi samo drugi supružnik radio takvo kućanstvo bi imalo pravo na naknadu WTC-FAM. No, zaposlenjem prvog supružnika već i uz minimalnu bruto plaću takvo kućanstvo gubi pravo na naknadu WTC-FAM što djeluje na povećanje PPS-a. S druge strane, naknada WTC-IND uzrokuje smanjenje PPS-a za sve tipove kućanstva.





Slika 5.10. Distribucija PPS-a za različite tipove kućanstava s obzirom na uvedene politike za povećanje isplativosti rada u Sloveniji

Napomena: Na slici je izražen iznos PPS-a u slučaju zaposlenja promatrane osobe uz plaću koja iznosi 50% PBP-a.

Izvor: Autorovi izračuni koristeći Euromod

Iz slike 5.10. proizlazi kako je naknada WTC-FAM efikasnija u smanjenju PPS-a za kućanstva tipa 1 i 4. Za kućanstvo tipa 1 u kojemu se samac zapošljava uz minimalnu bruto plaću naknada WTC-FAM smanjuje PPS za 20 postotnih bodova (s 60% na 40%), a naknada WTC-IND smanjuje PPS za 18 postotnih bodova. Povećanjem bruto plaće uz koju se samac može zaposliti smanjuje se utjecaj uvedenih naknada na smanjenje PPS-a pa kod samaca koji rade uz 60% PBP-a naknada WTC-FAM smanjuje PPS za oko 12 postotna boda (s 59% na 47%), a naknada WTC-IND ga smanjuje za 10 postotnih bodova. Naknada WTC-FAM ima najveći utjecaj na smanjenje PPS-a za kućanstvo tipa 4. U tom kućanstvu zaposlenjem prvog supružnika uz minimalnu bruto plaću naknada WTC-FAM smanjuje PPS za 41 postotnih bodova (s 80% na 39%), a utjecaj naknade WTC-IND je slabiji i ta naknada smanjuje PPS za 19 postotnih bodova. Naknada WTC-IND je efikasnija u smanjenju PPS-a za kućanstvo tipa 6, pa zapošljavanjem prvog supružnika uz minimalnu bruto plaću i radom drugog supružnika uz bruto plaću od 75% PBP-a naknada WTC-IND smanjuje PPS za 19 postotnih bodova (s 38% na 19%), a naknada WTC-FAM povećava PPS za 24 postotna boda.

Dakle, pokazalo se kako je naknada WTC-FAM efikasnija u smanjenju PPS-a za kućanstva tipa 1 i 4 koja imaju visok PPS i u kojima samo jedan odrasli član radi. S druge strane, naknada WTC-IND je efikasnija u smanjenju PPS-a za kućanstvo u kojima drugi odrasli član već radi, a prvi se zapošljava, ali takvo kućanstvo nema problem s visokim PPS-om.

5.2.3. Analiza utjecaja uvedenih reformi na siromaštvo i raspodjelu dohotka u Republici Sloveniji

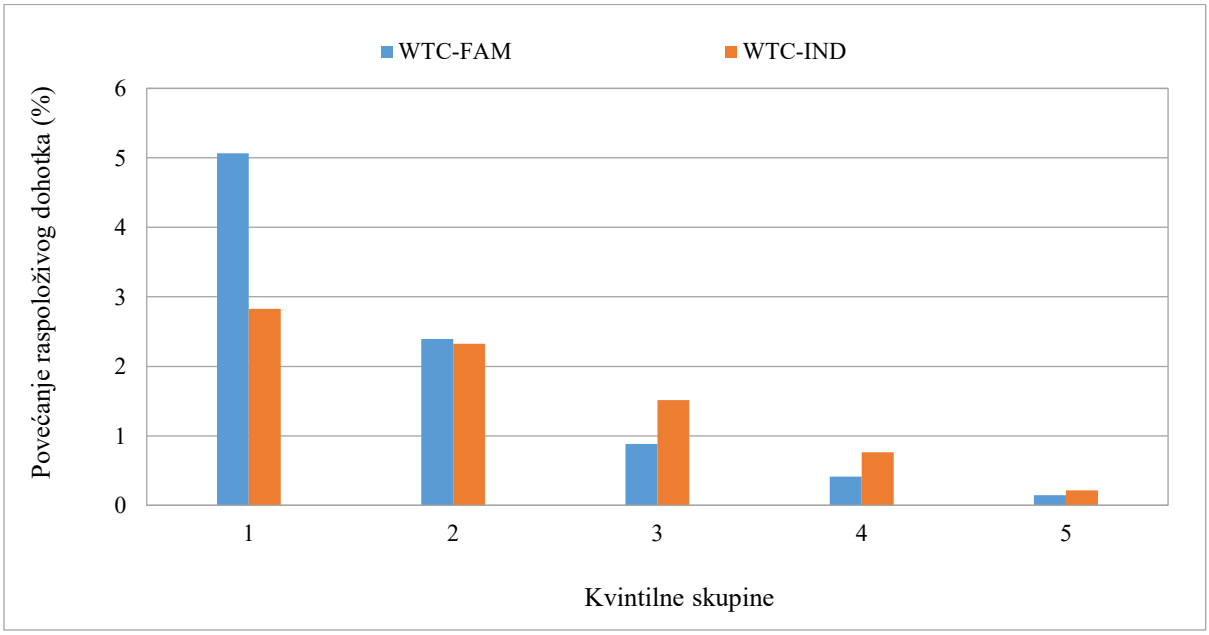
U ovom dijelu se na temelju anketnih podataka analiziraju distributivni učinci uvedenih naknada za zaposlene te njihov utjecaj na ukupnu stopu siromaštva u Sloveniji i posebno na stopu siromaštva zaposlenih osoba. Najprije se u tablici 5.8. analizira koliki postotak kućanstva prima naknade za zaposlene, te maksimalni i prosječni iznosi primljenih naknada. Vidljivo je kako naknada WTC-FAM ima veći maksimalni iznos i prosječni iznos od naknade WTC-IND. Tako je najveći dodijeljeni iznos naknada WTC-FAM u Sloveniji 372 eura mjesečno, a prosječni iznos je 121 eura. S druge strane, maksimalni iznos naknade WTC-IND je nešto manji i iznosi 207 eura, dok je prosječni dodijeljeni iznos 81 eura. Međutim, kako je naknada WTC-FAM izdašnija u dodijeljenim iznosima, nju prima manji broj kućanstava, oko 18% svih kućanstava u Sloveniji, a naknadu WTC-IND prima oko 25% kućanstava. Valja napomenuti kako u Sloveniji postoji i određeni broj složenih kućanstava pa je moguće da više osoba u jednom kućanstvu prima naknadu za zaposlene. Točnije, u 1,5% posto kućanstava više od jedne osobe u kućanstvu prima naknadu WTC-FAM, a u 4,1% kućanstava postoji više od jednog primatelja naknade WTC-IND.

Tablica 5.8. Distribucija uvođenja naknade za zaposlene među kućanstvima u Sloveniji, agregatni pokazatelji

	WTC-FAM	WTC-IND
Primatelji		
Broj kućanstava u kojima barem jedna jedinica prima naknadu (u tis.)	149	207
(% od ukupnog broja kućanstava u populaciji)	18,2	25,3
Broj kućanstava u kojima točno jedna jedinica prima naknadu (u tis.)	137	174
(% od ukupnog broja kućanstava u populaciji)	16,7	21,3
Broj kućanstava u kojima više od jedne jedinice primaju naknadu (u tis.)	12	33
(% od ukupnog broja kućanstava u populaciji)	1,5	4,1
Najviši neto iznos (Eur/ mjesečno)	372	207
Prosječni neto iznos (Eur/ mjesečno)	121	81

Izvor: Autorovi izračuni koristeći Euromod

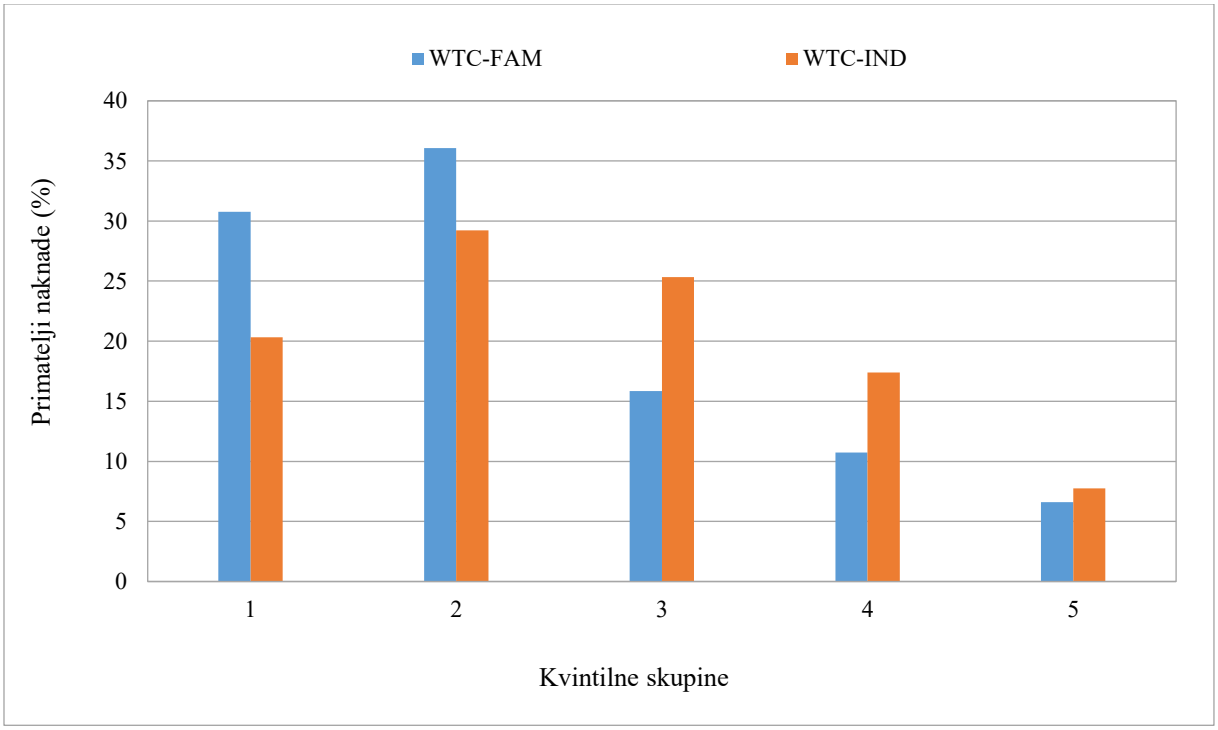
Na slici 5.11. analizira se utjecaj uvedenih naknada za zaposlene na distribuciju dohotka kućanstva po kvintilnim skupinama. Točnije, analizira se utjecaj naknada za zaposlene na postotno povećanje raspoloživog dohotka kućanstva. Kako se i očekivalo, pokazalo se da uvedene naknade najviše djeluju na povećanje raspoloživog dohotka nižih kvintilnih skupina. Međutim, uspoređujući dvije uvedene naknade, analiza otkriva da naknada WTC-FAM ima veći utjecaj na povećanje raspoloživog dohotka prve kvintilne skupine od naknade WTC-IND. Naime, naknada WTC-FAM povećava raspoloživi dohodak prve kvintilne skupine za 5,1%, a WTC-IND za 2,8%. U drugoj kvintilnoj skupini obje naknade imaju jednak utjecaj te povećavaju raspoloživi dohodak za oko 2,4%. S druge strane, u zadnje tri kvintilne skupine naknada WTC-IND je efikasnija u povećanju raspoloživog dohotka od naknade WTC-FAM.



Slika 5.11. Povećanje raspoloživog dohotka kućanstava u Sloveniji u odnosu na osnovni scenarij (%)

Izvor: Autorovi izračuni koristeći Euromod

Slika 5.12. analizira primatelje naknade za zaposlene prema kvintilnim skupinama kućanstava. Pokazuje se da se u prvoj kvintilnoj skupini nalazi oko 31% kućanstava, a u drugoj kvintilnoj skupini se nalazi 36% primatelja naknade WTC-FAM. Što se tiče naknade WTC-IND, u prve dvije kvintilne skupine nalazi se manje primatelja naknade WTC-IND nego naknade WTC-FAM. Preciznije, u prvoj kvintilnoj skupini se nalazi 20%, a u drugoj 29% primatelja naknade WTC-IND. Konačno, u zadnje tri kvintilne skupine nalazi se veći broj primatelja naknade WTC-IND, nego naknade WTC-FAM. Dakle, pokazalo se kako je naknada WTC-FAM koja se dodjeljuje s obzirom na dohodak obitelji više usmjerena na kućanstva s nižim primanjima od naknade WTC-IND koju mogu primati i pojedinci s niskom plaćom koji žive u bogatijim kućanstvima.



Slika 5.12. Primatelji naknade za zaposlene prema kvintilnim skupinama kućanstava u Sloveniji
Izvor: Autorovi izračuni koristeći Euromod

Na kraju ovog potpoglavlja analizira se kako novouvedene reforme utječu na smanjenje stope siromaštva. Stopa siromaštva se računa na standardnoj liniji siromaštva od 60% medijana ekvivalentnog raspoloživog dohotka kućanstva, a granica siromaštva je izračunata na temelju osnovnog scenarija. Prvo se u tablici 5.9. za osnovni i reformske scenarije računaju stope siromaštva za cjelokupnu populaciju, a potom se u tablici 5.10. analiziraju stope siromaštva zaposlene populacije.

U usporedbi s naknadom WTC-IND, za naknadu WTC-FAM se pokazalo da obuhvaća veći broj siromašnijih obitelji (kućanstva iz nižih kvintilnih skupina), raspoređena je na manji broj

kućanstava, pa poprima veće maksimalne i prosječne isplaćene iznose. Također se pokazalo da naknada WTC-FAM na granici od 60% medijana ima veći utjecaj na smanjenje stope siromaštva. Stopa siromaštva na granici od 60% medijana u osnovnom scenariju iznosi 14,1%, uvođenjem naknade WTC-FAM stopa siromaštva se smanjuje za 14% i iznosi 12,1%. Nadalje, uvođenjem naknade WTC-IND stopa siromaštva pada za oko 9% i iznosi 12,9%. Stoga je uvođenje naknade WTC-FAM utjecalo na izlazak 16 tisuća kućanstava iznad granice siromaštva, a uvođenje naknade WTC-IND je rezultirao izlaskom 10,5 tisuća kućanstva iznad linije siromaštva. Navedeno je pokazalo da je u Sloveniji (kao i u Hrvatskoj) naknada za zaposlene uz provjeru dohotka obitelji efikasnija je u smanjenju stope siromaštva nego naknada za zaposlene uz provjeru dohotka pojedinca, čime je potvrđena hipoteza **H3**.

Stopa siromaštva na granici od 40% medijana je dosta niska i iznosi 2,8%, a uvođenjem naknada WTC-FAM i WTC-IND stopa siromaštva se smanjuje za oko 0,2 postotna boda. U osnovnom scenariju se oko 29,5 tisuća kućanstva nalazi ispod razine siromaštva od 40% medijana, a uvođenje obje naknade oko tisuću kućanstva prelazi iznad linije siromaštva.

Dakle, kao i u potpoglavlju 5.2.3., u kojem se analizira utjecaj uvođenja naknada za zaposlene na smanjenje stope siromaštva u Hrvatskoj, u ovom potpoglavlju se također pokazalo da je i za Sloveniju smanjenje stope siromaštva intenzivnije u slučaju kada je granica siromaštva postavljena na 60% medijana, nego u slučaju kada je linija siromaštva postavljena na 40% medijana. Jedan od mogućih razloga za spomenutu činjenicu je taj što se ispod granice siromaštva od 40% medijana nalazi malen broj zaposlenih osoba pa naknade za zaposlene imaju ograničen učinak za tu podskupinu osoba.

Tablica 5.9. Utjecaj uvođenja naknade na stopu siromaštva u Sloveniji

	Osnovni scenarij	WTC-FAM	WTC-IND
Stopa siromaštva – **60% medijana**, u %	14,1	12,1	12,9
Promjene stope siromaštva u odnosu na osnovni scenarij, u %		-13,9	-8,7
Broj kućanstava ispod razine siromaštva – 60% medijana	138.743	122.802	128.075
Stopa siromaštva – **40% medijana**, u %	2,8	2,6	2,6
Promjene stope siromaštva u odnosu na osnovni scenarij, u %		-5,4	-4,4
Broj kućanstava ispod razine siromaštva – 40% medijana	29.580	28.437	28.626

Napomena: Pragovi linije siromaštva računani su na temelju osnovnog scenarija
Izvor: Autorovi izračuni koristeći Euromod

U tablici 5.10. analizira se stopa siromaštva zaposlene populacije. Pokazalo se kako u osnovnom scenariju za osobe koje su zaposlene svih 12 mjeseci stopa siromaštva na granici od 60% medijana iznosi 2,96%. Uvođenje naknade WTC-FAM smanjuje stopu siromaštva za 2 postotna boda, a utjecaj naknade WTC-IND na smanjenje stope siromaštva je nešto slabiji budući da uvođenje spomenute naknade smanjuje stopu siromaštva za 1,2 postotna boda. Može se primijetiti kako se stopa siromaštva smanjuje za gotovo isti iznos postotnih bodova kao i stopa siromaštva cjelokupne populacije. Međutim, realno smanjenje stope siromaštva je veće nego kada se promatra cjelokupna populacija, zbog činjenice da među zaposlenima postoji manji udio siromašnih nego u slučaju kada se promatra cjelokupna populacija (Figari, 2010). Tako na granici siromaštva od 60% medijana za osobe zaposlene svih 12 mjeseci, WTC-FAM smanjuje stopu siromaštva za 68%, a naknada WTC-IND za 41% posto. Uzmu li se u obzir zaposleni koji rade barem pola godine, onda je stopa siromaštva nešto veća i iznosi 4,24%. U tom slučaju na granici od 60% medijana, naknada WTC-FAM smanjuje stopu siromaštva za 59%, dok je naknade WTC-IND smanjuju svaka za 39%.

Tablica 5.10. Utjecaj uvođenja naknade na stopu siromaštva zaposlenih osoba u Sloveniji (u %)

	Osnovni scenarij	WTC-FAM	WTC-IND
Zaposleni svih 12 mjeseci			
Stopa siromaštva – 60 % medijana, u %	2,96	0,96	1,74
Promjene stope siromaštva u odnosu na osnovni scenarij, u %		-68	-41
Zaposleni 9 do 12 mjeseci			
Stopa siromaštva – 60 % medijana, u %	3,65	1,27	2,10
Promjene stope siromaštva u odnosu na osnovni scenarij, u %		-65	-43
Zaposleni 6 do 12 mjeseci			
Stopa siromaštva – 60 % medijana, u %	4,24	1,75	2,58
Promjene stope siromaštva u odnosu na osnovni scenarij, u %		-59	-39

Izvor: Autorovi izračuni koristeći Euromod

5.2.4. Analiza pokazatelja isplativosti rada u Republici Sloveniji

U ovom dijelu se na temelju anketnih podataka analizira utjecaj uvođenja politika za povećanje isplativosti rada na financijske poticaje za ulazak u svijet rada. Na početku se analizira populacija neaktivnih i nezaposlenih osoba koje će se promatrati (tzv. fleksibilnih osoba), promatra se distribucija uvedenih naknada za zaposlene prema određenim tipovima kućanstava te se analizira participacijska porezna stopa.

5.2.4.1. Distribucija naknada za zaposlene prema tipovima fleksibilnih osoba u Republici Sloveniji

U ovom dijelu se analizira distribuciju naknada za zaposlene prema odabranim tipovima fleksibilnih osoba, što je prikazano u tablici 5.11. Potencijalni primatelji su osobe koje ispunjavaju uvjete za primanje naknade za zaposlene, a svi koji ne zadovoljavaju uvjete nisu potencijalni primatelji. Potencijalni primatelji naknade se dodatno razvrstavaju u tri skupine prema iznosu dobivene naknade: (1) izvan dosega naknade – imaju preveliki dohodak da bi primali naknadu; (2) maksimalni iznos naknade i (3) pozitivan iznos naknade manji od maksimuma.

Tablica 5.11. Distribucija naknada za zaposlene prema odabranim tipovima fleksibilnih osoba Sloveniji, (u %)

	WTC-FAM	WTC-IND
Osobe s fleksibilnim supružnikom		
Nije potencijalni primatelj	1,5	10,1
Potencijalni primatelj	98,5	89,9
Maksimalan iznos naknade	0,5	2,0
Pozitivan iznos naknade manji od maksimuma	10,7	21,9
Izvan dosega naknade	87,4	65,9
Osobe s nefleksibilnim supružnikom		
Fleksibilni supružnik nije potencijalni primatelj	16,4	16,4
Fleksibilni supružnik je potencijalni primatelj	83,6	83,6
Maksimalan iznos naknade	0,6	2,9
Pozitivan iznos naknade manji od maksimuma	20,6	22,7
Izvan dosega naknade	62,4	58,0
Samci u višečlanim kućanstvima		
Nije potencijalni primatelj	18,8	18,8
Potencijalni primatelj	81,2	81,2
Maksimalan iznos naknade	6,7	6,3
Pozitivan iznos naknade manji od maksimuma	31,5	29,1
Izvan dosega naknade	43,0	45,8
Samci u jednočlanim kućanstvima		
Nije potencijalni primatelj	14,3	14,3
Potencijalni primatelj	85,7	85,7
Maksimalan iznos naknade	2,9	2,4
Pozitivan iznos naknade manji od maksimuma	30,6	28,6
Izvan dosega naknade	52,3	54,7
Samohrani roditelji		
Nije potencijalni primatelj	17,8	17,8
Potencijalni primatelj	82,2	82,2
Maksimalan iznos naknade	2,6	2,8
Pozitivan iznos naknade manji od maksimuma	41,8	28,1
Izvan dosega naknade	37,8	51,3

Izvor: Autorovi izračuni

Što se tiče osoba s fleksibilnim supružnikom vidljivo je da su u 98,5% slučajeva jedan ili oba supružnika u obitelji potencijalni primatelji naknade WTC-FAM. Maksimalni iznos naknade

prima oko 0,5% parova s oba fleksibilna supružnika, 10,7% ih prima pozitivan iznos manji od maksimuma, dok ih je 87,4% izvan dosega naknade. S druge strane, uvjete za primanje naknade WTC-IND ispunjava 89,9% osoba s fleksibilnim supružnikom, 2% ih prima maksimalni iznos naknade, 21,9% ih prima pozitivan iznos manji od maksimuma, dok ih se 65,9% nalazi izvan dosega naknade.

Promatraju li se osobe s nefleksibilnim supružnikom vidljivo je kako uvjete za primanje obje naknade zadovoljava njih 83,6%. Naknada WTC-IND je raspoređena na veći broj primatelja, njih 25,6%, dok naknadu WTC-FAM prima 21,2% osoba s nefleksibilnim supružnikom. Maksimalni iznos naknade WTC- IND prima 2,9% osoba s nefleksibilnim supružnika, a 22,7% ih prima naknadu manju od maksimuma. S druge strane, maksimalni iznos naknade WTC-FAM prima 0,6% osoba s nefleksibilnim supružnikom, a 20,6% ih prima iznos manji od maksimuma. Veći broj primatelja naknade WTC-IND je rezultat činjenice da u dohodovni cenzus te naknade ulazi samo dohodak promatrane (fleksibilne) osobe, dok u dohodovni cenzus naknade WTC-FAM ulazi i iznos dohotka drugog nefleksibilnog primatelja koju u većini slučajeva čini mirovina.Uspoređuju li se samci u jednočlanim i višečlanim kućanstvima, vidljivo je kako nešto veći postotak samaca u višečlanim kućanstvima prima naknade za zaposlene nego samaca u jednočlanim kućanstvima. Naknadu WTC-FAM prima 38,2% samaca u višečlanim kućanstvima i 33,4% samac u jednočlanim kućanstvima, dok naknadu WTC-IND prima 35,4% samaca i višečlanim kućanstvima i 31,0% samaca u jednočlanim kućanstvima. Za samohrane roditelje se pokazalo da bi ih puno veći broj primao naknadu WTC-FAM (44,4%), nego naknadu WTC-IND (30,9%).

5.2.4.2. Distribucija participacijske porezne stope u Republici Sloveniji

U ovom dijelu se analizira participacijska porezna stopa koja mjeri financijske poticaje za rad prilikom prelaska osoba koje su bile neaktivne ili nezaposlene svih 12 mjeseci u zaposlenost na puno radno vrijeme. PPS se analizira u osnovnom scenariju - na temelju sustava poreza i socijalnih naknada koji je vrijedio u 2017., te u dva dodatna reformska scenarija, u kojima su uvedene naknada za zaposlene WTC-FAM i WTC-IND.

U tablici 5.12. se analizira distribucija PPS-a za različite tipove obitelji na temelju osnovnog scenarija te za dva reformska scenarija u kojima su uvedene naknade za povećanje isplativosti rada. Prosječni PPS za cjelokupnu populaciju osoba izvan rada u osnovnom scenariju iznosi 43,9%, gdje 21,9% promatranih osoba ima PPS između 50 i 70%, dok vrlo visok PPS - iznad

70% ima 5,2% osoba izvan rada. Uvođenje naknade WTC-IND smanjuje prosječni PPS cjelokupne populacije za 0,7 postotna boda, dok ga uvođenje naknada WTC-FAM povećava za jedan postotni bod. Međutim, iako naknada WTC-FAM čak i povećava prosječni PPS cjelokupne populacije osoba izvan rada, ta naknada ima najveći utjecaj na smanjenje udjela onih s vrlo visokim PPS-om (većim od 70%) i to za 2 postotna boda (za 38%), dok ga naknada WTC-IND smanjuje za 1,1 (19%) postotna boda.

Tablica 5.12. Distribucija participacijske porezne stope nakon uvođenja naknada za zaposlene u Sloveniji (u %)

	Prosječni PPS	Distribucija odabranih tipova obitelji prema razredima PPS-a			
		< 30 %	[30%, 50%>	[50%, 70%>	≥ 70%
Ukupno					
Osnovni scenarij	43,9	5,5	67,4	21,9	5,2
WTC-FAM	44,9	6,3	61,7	28,8	3,2
WTC-IND	43,2	7,1	67,6	21,2	4,1
Parovi - fleksibilni supružnik ne radi					
Osnovni scenarij	59,3	2,6	24,2	37,6	35,5
WTC-FAM	52,4	6,7	29,4	60,1	3,8
WTC-IND	57,7	4,4	23,5	43,3	28,9
Parovi - fleksibilni supružnik radi					
Osnovni scenarij	41,5	2,2	82,3	14,5	1,1
WTC-FAM	47,8	0,6	60,9	35,1	3,4
WTC-IND	40,9	4,6	80,7	14,0	0,7
Osobe s nefleksibilnim supružnikom					
Osnovni scenarij	42,8	10,0	61,6	24,6	3,7
WTC-FAM	41,8	12,5	60,8	25,2	1,5
WTC-IND	42,3	12,3	59,8	25,6	2,3
Samci u višečlanim kućanstvima					
Osnovni scenarij	38,7	11,5	75,5	8,4	4,6
WTC-FAM	38,2	12,6	75,0	7,5	5,0
WTC-IND	38,6	12,1	75,4	7,4	5,2
Samci u jednočlanim kućanstvima					
Osnovni scenarij	48,6	1,3	61,1	33,7	3,9
WTC-FAM	46,6	1,9	72,1	24,5	1,5
WTC-IND	46,9	1,9	68,6	28,0	1,5
Samohrani roditelji					
Osnovni scenarij	56,2	0,5	18,5	68,5	12,6
WTC-FAM	51,6	9,2	15,3	70,1	5,4
WTC-IND	55,5	0,5	19,2	69,5	10,8

Izvor: Autorovi izračuni

Analiza na temelju hipotetskih podataka je pokazala da se utjecaj naknada WTC-FAM i WTC-IND na smanjenje PPS-a razlikuje ovisno o tipu kućanstva. Naime, naknada WTC-FAM se provjerava prema dohotku obitelji pa kao takva ima veći utjecaj na smanjenje PPS-a u obiteljima gdje niti jedan odrasli član ne radi, odnosno u obiteljima u kojima nema dohotka od plaće (obitelji s najvišim PPS-om). Jedan od primjera takvih obitelji su fleksibilni parovi u kojima ne radi

nijedan supružnik, gdje se PPS smanjuje za 7 postotnih bodova (s 59,3% na 52,4%) i samohrani roditelji koji ne rade gdje se PPS smanjuje za oko 5 postotnih bodova (s 56,2% na 51,6%). Nadalje, u osnovnom scenariju udio parova u kojima nijedan supružnik ne radi i čiji je PPS veći od 70% iznosi 35%, a uvođenjem naknade WTC-FAM taj udio se smanjio na 4%. Za samohrane roditelje je taj efekt nešto manji, 12,6% samohranih roditelja ima PPS veći od 70%, a uvođenjem naknade WTC-FAM udio se smanjio na 5,4%. Suprotno od prethodna dva tipa obitelji, za parove u kojima jedan supružnik već radi pokazalo se da uvođenje naknade WTC-FAM povećava prosječni PPS za 6 postotnih bodova (s 41,5% na 47,8%) i time stvara negativne poticaje za rad.

Što se tiče analize utjecaja naknade WTC-IND na PPS prethodno spomenuta tri tipa obitelji, pokazalo se da uvođenje te naknade smanjuje PPS za sva tri tipa. Kod parova u kojima nijedan supružnik ne radi naknada WTC-IND smanjuje PPS za 1,6 postotnih bodova (s 59,3% na 57,7%), dok se kod samohranih roditelja PPS smanjuje za 0,7 postotna boda (s 56,2% na 55,5%), što je za oba tipa obitelji dosta manje smanjenje PPS nego kod uvođenja naknade WTC-FAM. Međutim, za razliku od naknade WTC-FAM, naknada WTC-IND smanjuje PPS parova s jednim zaposlenim supružnikom za 0,6 postotna boda (s 41,5% na 40,9%), dok je naknada WTC-FAM povećavala PPS za taj tip obitelji.

Što se tiče samaca u višečlanim i jednočlanim kućanstvima, takve osobe nemaju partnera pa se, kao i kod naknade WTC-IND, prilikom uvođenja naknade WTC-FAM u obzir uzima samo dohodak promatranih pojedinaca, što dovodi do činjenice da je utjecaj obje naknade na smanjenje PPS-a gotovo jednak. Tako PPS samaca u jednočlanim kućanstvima u osnovnom scenariju iznosi 48,6%, a 37,6% ih ima PPS veći od 50%. Uvođenje naknada WTC-FAM i WTC-IND smanjuje redom prosječni PPS za 2,0 i 1,7 postotnih bodova, a udio samaca u jednočlanim kućanstvima s PPS-om većim od 50% se redom smanjuje za 11,6 i 8,1 postotnih bodova. Samci u višečlanim kućanstvima imaju najniži PPS od svih promatranih skupina koji u osnovnom scenariju iznosi 38,7%, a također imaju i najmanji udio osoba s PPS-om većim od 50% koji iznosi 13%. Uvođenje naknada WTC-FAM i WTC-IND smanjuje PPS za malene iznose, naknada WTC-FAM ga smanjuje za 0,5 postotnih bodova, a naknada WTC-IND ga smanjuje za 0,1 postotni bod.

Sumarno, za Sloveniju je također potvrđena hipoteza **H2a** koja tvrdi da je naknada uz provjeru dohotka obitelji efikasnija u smanjenju PPS-a najranjivijih skupina od naknada uz provjeru dohotka pojedinca. Potvrđuje se i hipoteza **H2b** koja tvrdi da naknada uz provjeru dohotka obitelji povećava PPS parova u kojima jedan supružnik radi. S druge strane, promatrajući sve

podskupine kućanstva pokazalo se da naknada uz provjeru dohotka pojedinca smanjuje PPS svih skupina, čime se i za Sloveniju potvrdila hipoteza **H2c**.

5.3. Komparativna analiza utjecaja uvedenih reformi na isplativost rada u Republici Hrvatskoj i Republici Sloveniji

Komparativna analiza utjecaja naknada za zaposlene na isplativost rada u Hrvatskoj i Sloveniji počinje analizom hipotetskih kućanstava. Valja napomenuti kako su naknade WTC-FAM i WTC-IND definirane na način da relativni udio troška uvođenja naknada u ukupnim prihodima bude jednak u Hrvatskoj i Sloveniji, što omogućuje usporedivost među zemljama.[34] Prvo se u tablici 5.13. analiziraju promjene PPS-a nastale uvođenjem naknada za zaposlene za šest tipova kućanstava u kojima se promatrani član zapošljava uz minimalnu bruto plaću. Stupac (1) označava PPS na osnovu trenutnog (baznog) sustava poreza i socijalnih naknada, a stupci (2) i (3) prikazuju pad PPS-a nastao uvođenjem naknada za zaposlene, mjeren u postotnim bodovima.

Tablica 5.13. Komparativna analiza utjecaja naknada za zaposlene na PPS u Hrvatskoj i Sloveniji za odabrane tipove kućanstva u kojima se promatrani član zapošljava uz minimalnu bruto plaću

			Smanjenje PPS-a nakon uvođenja naknada za zaposlene, postotni bodovi	
		PPS (bazni), %	WTC-FAM	WTC-IND
		(1)	(2)	(3)
Tip 1	Hrvatska	58	19	17
	Slovenija	60	21	18
Tip 2	Hrvatska	102	39	17
	Slovenija	80	40	18
Tip 3	Hrvatska	65	39	17
	Slovenija	80	40	18
Tip 4	Hrvatska	98	39	17
	Slovenija	80	40	18
Tip 5	Hrvatska	28	-10	17
	Slovenija	41	-24	18
Tip 6	Hrvatska	32	-10	17
	Slovenija	38	-24	18

Izvor: Autorovi izračuni

Za kućanstva tipa 1 do 4, uvođenje naknade WTC-FAM utječe na pad PPS-a, a taj pad je približno jednak u obje zemlje. Tako u obje zemlje uvođenje naknade WTC-FAM ima najveći utjecaj na pad PPS-a za kućanstva tipa 2 do 4; za spomenuta kućanstva u Hrvatskoj PPS pada za 39 postotnih bodova, dok u Sloveniji pada za 40 postotnih bodova. Za kućanstvo tipa 1

[34] Više o definicijama reformi WTC-FAM i WTC-IND vidjeti u poglavljima 5.1.1. i 5.2.1.

naknada WTC-FAM smanjuje PPS za manji broj postotnih bodova i to za 19 postotnih bodova u Hrvatskoj i 21 postotnih bodova u Sloveniji. S druge strane, za kućanstva tipa 5 i 6 se pokazalo da naknada WTC-FAM utječe na povećanje PPS-a, a povećanje je puno veće u Sloveniji nego u Hrvatskoj. Preciznije, u Sloveniji se za kućanstva tipa 5 i 6, PPS povećava za 24 postotnih bodova, dok se PPS u Hrvatskoj povećava za 10 postotnih bodova.

Naknada WTC-IND utječe na pad PPS-a za sve tipove kućanstva u obje zemlje, a pad je gotovo jednak za sve promatrane tipove kućanstva. Preciznije, ako se promatrani član kućanstva zaposli uz minimalnu bruto plaću, uvođenje naknade WTC-IND smanjuje PPS za 17 postotnih bodova u Hrvatskoj, dok ga u Sloveniji smanjuje za 18 postotnih bodova.

Nakon analize hipotetskih kućanstava slijedi komparativna analiza utjecaja naknada WTC-FAM i WTC-IND na PPS za različite podskupine kućanstava koristeći anketne podatke. Pokazalo se da u obje zemlje naknada WTC-FAM najviše smanjuje PPS parova u kojima nijedan supružnik ne radi i samohranih roditelja, a to su ujedno i podskupine kućanstava s najvećim PPS-om. U Hrvatskoj se uvođenjem naknade WTC-FAM smanjuje PPS parova u kojima ne radi nijedan supružnik za 12,6 postotnih bodova, a u Sloveniji se smanjuje za 6,9 postotnih bodova. Smanjuje se i udio parova u kojima ne radi nijedan supružnik i koji imaju vrlo visok PPS i to za 78% u Hrvatskoj (s 9,7% na 2,2%) i za 89% u Sloveniji (s 35,5% na 3,8%). Nadalje, uvođenjem naknade WTC-FAM smanjuje se PPS u Hrvatskoj za 19,6 postotnih bodova, dok je u Sloveniji smanjenje PPS-a dosta manje i iznosi 4,6 postotnih bodova. U Hrvatskoj se udio samohranih roditelja s vrlo visokim PPS-om smanjuje za 85% (42,9% na 23,2%), a u Sloveniji se smanjuje za 57% (12,6% na 5,4%). Što se tiče negativnog utjecaja naknade WTC-FAM na isplativost rada, pokazalo se da kod parova u kojima fleksibilni supružnik radi PPS raste u obje zemlje za oko 6 postotnih bodova. U Hrvatskoj se udio parova s zaposlenim fleksibilnim supružnikom koji imaju vrlo visok PPS čak i neznatno smanjuje za 0,2 postotnih bodova (s 0,7% na 0,5%), dok se u Sloveniji taj udio povećava za 2,3 postotnih bodova (s 1,1% na 3,4%).

S druge strane, u Hrvatskoj naknada WTC-IND ima najveće smanjenje za parove s nefleksibilnim supružnikom i to za 11,4 postotnih bodova, a kod njih se u Sloveniji PPS smanjuje za 0,5 postotnih bodova. Međutim, u obje zemlje je to podskupina kućanstva s PPS-om manjim od prosjeka. Naknada WTC-IND u Sloveniji pak najviše smanjuje PPS za samce u jednočlanim kućanstvima kod kojih se PPS smanjuje za 1,7 postotnih bodova, a u Hrvatskoj se za tu podskupinu kućanstva PPS smanjuje za veći iznos i to za 2,4 postotnih bodova.

Što se tiče ukupnog utjecaja naknada WTC-FAM i WTC-IND na isplativost rada nezaposlenih i neaktivnih osoba, pokazalo se da naknada WTC-FAM smanjuje PPS svih neaktivnih i nezaposlenih osoba u Hrvatskoj i to za 2,3 postotnih bodova, dok se za Sloveniju pokazalo da spomenuta naknada povećava PPS za jedan postotni bod. Međutim, naknada WTC-FAM u obje zemlje smanjuje udio osoba izvan rada s vrlo visokim PPS-om i to za 2 postotna boda. Nadalje, naknada WTC-IND smanjuje iznos PPS-a u obje zemlje, a smanjenje je veće u Hrvatskoj nego u Sloveniji; uvođenjem naknade WTC-IND PPS se u Hrvatskoj smanjuje za 6,8 postotnih bodova, dok se u Sloveniji smanjuje za 0,7 postotnih bodova. Dodatno, udio osoba izvan rada s vrlo visokim PPS-om se smanjuje za 1,8 postotnih bodova u Hrvatskoj, te za 1,1 postotnih bodova u Sloveniji.

Tablica 5.14. Komparativna analiza utjecaja naknada za zaposlene na distribuciju PPS-a u Hrvatskoj i Sloveniji (u %)

	Hrvatska		Slovenija	
	Prosječni PPS	Udio osoba s vrlo visokim PPS-om	Prosječni PPS	Udio osoba s vrlo visokim PPS-om
Parovi - fleksibilni supružnik ne radi				
Osnovni scenarij	39,2	9,7	59,3	35,5
WTC-FAM	26,6	2,2	52,4	3,8
WTC-IND	31,9	4,7	57,7	28,9
Parovi - fleksibilni supružnik radi				
Osnovni scenarij	29,4	0,7	41,5	1,1
WTC-FAM	35,3	0,5	47,8	3,4
WTC-IND	20,8	0,1	40,9	0,7
Osobe s nefleksibilnim supružnikom				
Osnovni scenarij	30,9	4,2	42,8	3,7
WTC-FAM	24,6	1,0	41,8	1,5
WTC-IND	19,5	1,1	42,3	2,3
Samci u višečlanim kućanstvima				
Osnovni scenarij	27,4	0,4	38,7	4,6
WTC-FAM	25,0	0,1	38,2	5,0
WTC-IND	24,9	0,1	38,6	5,2
Samci u jednočlanim kućanstvima				
Osnovni scenarij	35,2	1,0	48,6	3,9
WTC-FAM	32,4	1,0	46,6	1,5
WTC-IND	32,8	1,0	46,9	1,5
Samohrani roditelji				
Osnovni scenarij	42,9	14,8	56,2	12,6
WTC-FAM	23,2	2,2	51,6	5,4
WTC-IND	34,7	1,6	55,5	10,8
Ukupno				
Osnovni scenarij	31,2	2,8	43,9	5,2
WTC-FAM	28,9	0,8	44,9	3,2
WTC-IND	24,4	1,0	43,2	4,1

Izvor: Autorovi izračuni

Dakle, promatrajući sve osobe izvan rada empirijska analiza je pokazala da su naknade WTC-FAM i WTC-IND uspješnije u poboljšanju isplativosti rada u Hrvatskoj nego u Sloveniji, dok je analiza hipotetskih kućanstava pokazala da spomenute naknade u obje zemlje smanjuju PPS za približno iste iznose. Naime, iz tablica 5.5. i 5.11. proizlazi da prema anketnim podacima u Hrvatskoj postoji veći broj zaposlenih osoba koje primaju maksimalni iznos naknada WTC-FAM i WTC-IND, pa je i utjecaj tih naknada na smanjenje PPS-a veći u Hrvatskoj nego u Sloveniji.

6. ZAKLJUČAK

Izdašni sustavi socijalnih naknada mogu smanjiti poticaje za rad neaktivnih i nezaposlenih osoba. Naime, ako neaktivne i nezaposlene osobe svojim ponovnim zapošljavanjem izgube pravo na izdašne naknade iz socijalnog sustava, to može smanjiti poticaje takvih osoba za pronalaskom i prihvaćanjem novog zaposlenja. Spomenuta činjenica je navela više od polovine zemalja EU-a na uvođenje politika za povećanje isplativosti rada kojima je cilj povećati raspoloživi dohodak zaposlenim osobama koje mogu ostvariti samo niska primanja.

Glavni cilj disertacije je bio analizirati utjecaj uvođenja odabranih politika za povećanje isplativosti rada na poticaje za rad i stopu siromaštva u Republici Hrvatskoj i Republici Sloveniji. Promatrale su se osobe izvan rada i njihov hipotetski prelazak u svijet rada, a kao glavni pokazatelj isplativosti rada izračunavala se je participacijska porezna stopa (PPS) koja mjeri koliki će dio bruto plaće ostvarene na novom poslu biti izgubljen iz proračuna kućanstava zbog povećanja iznosa plaćenih poreza i smanjenja iznosa primljenih socijalnih naknada. Analiza je provedena koristeći hipotetske i anketne podatke, a glavni alat koji se koristio su mikrosimulacijski modeli poreza i socijalnih naknada kojima se simuliraju iznosi doprinosa, poreza i socijalnih naknada na razni pojedinaca i kućanstava. Koristili su se miCROmodA za Hrvatsku i slovenski modul EUROMOD-a za Sloveniju, pri čemu su u oba mikrosimulacijska modela ugrađena pravila iz sustava poreza i socijalnih naknada koja su za obje zemlje vrijedila na dan 30. lipnja 2017. Za Hrvatsku su se koristili podaci iz Ankete o dohotku stanovništva za 2016., a za Sloveniju podaci dobiveni EU-SILC anketom za 2016. Spomenute ankete su provedene prema istom metodološkom obrascu, a vrijednosti dohodovnih varijabli iz anketa odnosile su se na stanje u 2015. te su dodatno prilagođene na razinu iz 2017. korištenjem koeficijenata prilagodbe zasnovanih na službenoj statistici.

Nakon uvoda u kojemu su definirani ciljevi, hipoteze i znanstveni doprinos istraživanja, u drugom poglavlju analizira se stanje na tržištu rada u 2017., opisali su se koncept i mjerenje isplativosti rada. U trećem poglavlju su opisani metodologija i podaci. Analiza stanja na tržištu rada je pokazala da se Hrvatska nalazi među zemljama s najnižom stopom zaposlenosti, koja iznosi 63,6%, a jedino su Grčka i Italija lošije od Hrvatske. Nadalje, Hrvatska ima i sedmi najviši udio neaktivne i nezaposlene populacije u radno sposobnoj populaciji od 16,7%. S druge strane, susjedna zemlja Slovenija se po navedenim pokazateljima nalazi u puno boljem položaju od Hrvatske. Prema stopi zaposlenosti od 73,4% Slovenija se nalazi u sredini zemalja EU-a, a ima i peti najniži udio neaktivne i nezaposlene populacije u radno sposobnoj, od 9,1%. Dakle,

pokazalo se je da u usporedbi sa susjednom zemljom Slovenijom, ali i ostalim zemljama EU-a, Hrvatska je zemlja s niskom zaposlenošću i visokim udjelom neaktivnih i nezaposlenih osoba u radno sposobnoj populaciji. Stoga za dostizanje planirane stope zaposlenosti za EU do 2020. od najmanje 75%, Hrvatska mora potaknuti na zapošljavanje značajan broj osoba izvan svijeta rada.

U četvrtom poglavlju su se analizirali financijski poticaji za ulazak neaktivnih i nezaposlenih osoba u stanje zaposlenosti. Prvo je provedena analiza isplativosti rada na hipotetskim kućanstvima koja je pokazala kako u obje zemlje određeni tipovi kućanstava imaju slabe financijske poticaje za rad (vrlo visok PPS), po čemu se ističu samohrani roditelji i parovi s djecom u kojima ne radi nijedan supružnik. Potom se, koristeći reprezentativne anketne podatke, analizirala distribucija PPS-a, čime se nastojalo utvrditi stanje na području isplativosti rada u Hrvatskoj te napraviti usporedbu Hrvatske sa susjednom zemljom Slovenijom. U tu svrhu se testirala hipoteza **H1**, koja tvrdi da je prosječan PPS za osobe izvan rada u Hrvatskoj umjerene veličine, uz značajan postotak osoba s visokim i vrlo visokim PPS-om. Testirale su se i dvije pomoćne hipoteze. Prvom pomoćnom hipotezom **H1a** je ispitana istinitost tvrdnje da vjerojatnost vrlo visokog PPS-a za osobe izvan rada pada sa stupnjem njihova obrazovanja i s razinom tržišnog dohotka koji ostvaruju njihov supružnik i ostali članovi kućanstva, a raste s brojem maloljetne djece. Drugom pomoćnom hipotezom **H1b**, koja se temeljila na komparativnoj analizi isplativosti rada između Hrvatske i Slovenije, ispitana je istinitost tvrdnje da Slovenija ima viši PPS i veći udio osoba izvan rada s visokim i vrlo visokim PPS-om nego Hrvatska.

Rezultati su pokazali da osobe izvan rada u Hrvatskoj imaju prosječni PPS koji je umjerene veličine i iznosi 31,2%, te da 9% osoba izvan rada ima visok i vrlo visok PPS (većim od 50%), čime se potvrdila hipoteza **H1**. Nadalje, vrlo visok PPS ima 2,8% osoba izvan rada u Hrvatskoj, a logit modelom su se analizirale odrednice vrlo visokog PPS-a. Rezultati dobiveni na temelju logit modela pokazuju da vjerojatnost vrlo visokog PPS-a za osobe izvan rada u Hrvatskoj pada sa stupnjem njihova obrazovanja i s razinom tržišnog dohotka koji ostvaruju njihov supružnik i ostali članovi kućanstva, dok raste s brojem maloljetne djece, čime se potvrdila hipoteza **H1a**. Komparativna analiza Hrvatske i Slovenije je utvrdila da Slovenija ima viši prosječni PPS nego Hrvatska i on iznosi 43,9%, što je za 12,7 postotnih bodova više nego u Hrvatskoj. Slovenija ima puno veći udio osoba s visokim i vrlo visokim PPS-om, koji iznosi 27,1%, a u Hrvatskoj taj udio iznosi 9%, čime se potvrdila i hipoteza **H1b**.

Kako bi se istražili potencijalni mehanizmi za poboljšanje isplativosti rada osoba s visokim i vrlo visokim PPS-om, u petom poglavlju se u hrvatski i slovenski mikrosimulacijski model

poreza i socijalnih naknada ugrađuju odabrane politike za povećanje isplativosti rada. Uvode se dvije vrste politika za povećanje isplativosti rada koje su nazvane „naknade za zaposlene“, a osmišljene su po uzoru na britansku WTC naknadu (engl. *Working Family Tax Credit*). Prva naknada, WTC-FAM, provjerava se s obzirom na dohodak obitelji, a druga naknada, WTC-IND, s obzirom na dohodak pojedinca. Dodatno, u hrvatski sustav je implementirana i treća naknada, ETC-IND, koja je oblikovana po uzoru na slovački ETC (engl. *Employee tax credit*), i provjerava se s obzirom na dohodak pojedinaca. Bargain i Orsini (2006) navode da, iako postoji opći konsenzus o potrebi uvođenja politika za povećanje isplativosti rada, postoje dvojbe oko dizajna odabranih politika i o tome hoće li jedinica promatranja biti pojedinac ili obitelj. Tako su u ovom radu implementirana oba tipa naknada (provjeravanih prema dohotku obitelji i pojedinca), kako bi se ilustrirali eventualni različiti utjecaji pojedinog tipa naknade na poticaje za rad. Sve tri naknade u Hrvatskoj su modificirane na način da je njihov trošak za državni proračun jednak 1,5 mlrd. kuna. U svrhu komparativne analiza Hrvatske i Slovenije, naknade u Sloveniji su definirane tako da relativni udio ukupnog troška uvođenja reforme u ukupnom bruto dohotku svih kućanstava bude jednak u Hrvatskoj i Sloveniji. Tako je za Sloveniju dobiveno da ukupni trošak svake od reformi iznosi 200 milijuna eura. U istom poglavlju su testirane druga i treća hipoteza disertacije koje ispituju utjecaj uvedenih naknada za zaposlene na isplativost rada i stopu siromaštva.

Hipotezom **H2** ispitana je tvrdnja da naknada za zaposlene uz provjeru dohotka obitelji i naknada za zaposlene uz provjeru dohotka pojedinca imaju različite učinke na promjenu PPS-a pojedinih skupina osoba izvan rada. Uz glavnu hipotezu, testirale su se i tri pomoćne hipoteze. Prva pomoćna hipoteza **H2a** testirala je tvrdnju da je za najranjivije skupine naknada uz provjeru dohotka obitelji efikasnija u smanjenju PPS-a nego naknada uz provjeru dohotka pojedinca. Drugom pomoćnom hipotezom **H2b** ispitivalo se postojanje negativnog utjecaja naknada uz provjeru dohotka obitelji na isplativost rada pa se testirala tvrdnja da naknada uz provjeru dohotka obitelji povećava PPS parova u kojima jedan supružnik radi. Trećom pomoćnom hipotezom **H2c** provjeravala se tvrdnja da naknada uz provjeru dohotka pojedinca smanjuje PPS svih skupina.

Analiza uvedenih naknada za zaposlene je pokazala da njihov utjecaj na PPS ovisi o tipu naknade. Rezultati pokazuju da u Hrvatskoj naknada WTC-FAM smanjuje PPS samohranih roditelja za 19,6 postotnih bodova (s 42,9% na 23,2%), a naknada WTC-IND smanjuje PPS za 8,2 postotnih bodova. Za parove s oba fleksibilna supružnika izvan rada, naknada WTC-FAM smanjuje PPS za 12,6 postotnih bodova (s 39,2% na 26,6%), dok ga WTC-IND smanjuje za 7,3

postotna boda. U Sloveniji PPS parova s oba fleksibilna supružnika izvan rada iznosi 59,3%, naknada WTC-FAM smanjuje PPS za 6,9 postotnih bodova, a naknada WTC-IND ga smanjuje za 1,6 postotnih boda. Što se tiče samohranih roditelja u Sloveniji kod kojih PPS iznosi 56,2%, naknada WTC-FAM smanjuje PPS za 4,6 postotnih bodova, a naknada WTC-IND ga smanjuje za 1,6 postotnih bodova. Dakle, za obje zemlje se pokazalo da je za podskupine kućanstva s najvišim PPS-om (samohrani roditelji i parovi s oba fleksibilna supružnika izvan rada) naknada WTC-FAM efikasnija u smanjenju PPS-a nego naknada WTC-IND, čime se potvrdila pomoćna hipoteza **H2a**.

Međutim, iako naknada WTC-FAM može biti efikasna u poticanju zapošljavanja „najranjivijih" skupina osoba izvan rada, pokazalo se kako ta naknada u obje zemlje ima negativne poticaje za rad parova s jednim zaposlenim fleksibilnim supružnikom, čime se potvrdila pomoćna hipoteza **H2b**. Naime, uvođenjem naknade WTC-FAM PPS parova s jednim zaposlenim fleksibilnim supružnikom u Hrvatskoj raste za 5,9 postotnih bodova (s 29,4% na 35,3%), a u Sloveniji raste za 6,3 postotnih bodova (s 41,5% na 47,8%). S druge strane, naknada WTC-IND je u obje zemlje manje efikasna u poboljšanju poticaja za rad spomenutih „ranjivih" skupina, no ona ujedno poboljšava poticaje za rad svih skupina, a tako i parova u kojima jedan supružnik radi, čime se je potvrdila pomoćna hipoteza **H2c**.

Nakon što se potvrdila druga hipoteza, testirana je i hipoteza **H3**, koja tvrdi da je naknada za zaposlene uz provjeru dohotka obitelji efikasnija u smanjenju stope siromaštva nego naknada za zaposlene uz provjeru dohotka pojedinca. Analiza stope siromaštva u obje zemlje je pokazala da naknada WTC-FAM smanjuje stopu siromaštva cjelokupne populacije i populacije zaposlenih osoba više nego naknada WTC-IND. Naime, na granici siromaštva od 60%, stopa siromaštva cjelokupne populacije (osoba zaposlenih svih 12 mjeseci) u Hrvatskoj iznosi 20,4% (4,15%), dok naknada WTC-FAM smanjuje stopu siromaštva za 8,4% (47%), a naknada WTC-IND je smanjuje za 5,0% (23%). Nadalje, na granici siromaštva od 60%, stopa siromaštva cjelokupne populacije (osoba zaposlenih svih 12 mjeseci) u Sloveniji je nešto niža nego u Hrvatskoj i iznosi 14,1% (2,96%), naknada WTC-FAM smanjuje stopu siromaštva za 13,9% (68%), a naknada WTC-IND je smanjuje za 8,7% (41%). Valja naglasiti da se u Hrvatskoj dodatno ispitivao i utjecaj naknade ETC-IND na poticaje za rad i stopu siromaštva, ali se pokazalo da je naknada ETC-IND manje efikasna u poboljšanju poticaja za rad i stope siromaštva od naknade WTC-IND.

Sumarno, što se tiče poticaja za rad u obje zemlje, pokazalo se da postoji puno više osoba izvan rada za koje naknada WTC-FAM ima negativan utjecaj na poticaje za rad nego onih u kojima je ona posebno efikasna. Preciznije, u Hrvatskoj se pokazalo da obje naknade (WTC-FAM i WTC-IND) smanjuju prosječni PPS, ali je ukupni efekt smanjenja PPS-a veći u scenariju u kojem se uvodi naknada WTC-IND. Nadalje, u Sloveniji negativan učinak naknade WTC-FAM na poticaje za rad u potpunosti prevladava njene pozitivne učinke, pa je uvođenjem naknade WTC-FAM prosječni PPS čak i viši. Stoga se u obje zemlje sa stajališta poticaja za rad efikasnijom pokazala naknada WTC-IND, koja se provjerava s obzirom na dohodak pojedinaca, te koja je po svojem dizajnu raspoređena na veći broj primatelja. Nadalje, ako bi se uz uvođenje naknada uz provjeru dohotka pojedinca nastojalo dodatno povećati poticaje za rad ranjivih skupina, potrebno je u spomenutu naknadu ugraditi dodatne elemente koji bi se posebno odnosili na „najranjivije“ skupine (Bargain i Orsini, 2007).

Na kraju valja naglasiti ograničenja istraživanja. Ograničenja istraživanja se očituju u ograničenjima anketnih podataka kao i mikrosimulacijskih modela miCROmod-a i EUROMOD-a. Ograničenja u podacima posljedično smanjuju točnost procjena mikrosimulacijskih modela koji pak koriste te podatke. Neka od ograničenja podataka su nedostatak informacija o imovini i agregiranje varijabli dohotka na godišnjoj razini čime se onemogućuje precizno definiranje dohodovnih cenzusa koji se koriste u simulaciji programa socijalne pomoći. Agregiranost više vrsta socijalnih naknada u jednu varijablu također smanjuje točnost procjena modela. Nadalje, zbog nedostatka preciznih podataka o svim vrstama socijalnih naknada i poreznih davanja, u mikrosimulacijske modela se ugrađuju samo najznačajnije politike iz sustava poreza i socijalnih naknada u pojedinoj državi. Porezna evazija također nije modelirana u modelu zbog nedostatka podataka. Međutim, uz sva navedena ograničenja, korišteni mikrosimulacijski modeli i anketni podaci daju reprezentativnu sliku stanja u obje analizirane države.

POPIS LITERATURE

1. Adam, S., Brewer, M. i Shephard, A. (2006) Financial work incentives in Britain: Comparisons over time and between family types. *Working Paper 06/20*, Institute for Fiscal Studies.
2. Adam, S. i Browne, J. (2010) Redistribution, work incentives and thirty years of UK tax and benefit reform. *Working Paper 10/24*, Institute for Fiscal Studies.
3. Amemiya, T., 1985. *Advanced econometrics*. Cambridge Mass.: Harvard University Press.
4. Bargain, O. i Orsini, K. (2006) In-work policies in Europe: killing two birds with one stone?. *Labour Economics*, 13 (6), str. 667-697.
5. Bargain, O. i Orsini, K. (2007) Beans for Breakfast? How Exportable is the British Workfare Model?. U Bargain, O., ur., *Micro-Simulation in Action (Research in Labor Economics, Volume 25)*, Emerald Group Publishing Limited, str.165 - 198.
6. Bargain, O., Caliendo, M., Haan, P. i Orsini, K. (2010) "Making work pay" in a rationed labor market. *Journal of Population Economics*, 23(1), str 323–351, https://doi.org/10.1007/s00148-008-0220-9
7. Bartles, C. i Pestel, N. (2016) Short- and long-term participation tax rates and their impact on labor supply. *Int Tax Public Finance*, 23, str. 1126–1159. doi:10.1007/s10797-016-9400-9
8. Bejaković, P. (2003) Smanjivanje dugotrajne nezaposlenosti u Hrvatskoj. *Financijska teorija i praksa*, 27 (4), str. 581-607.
9. Bejaković, P. (2005) The Role of Economic and Political Measures on the Palliation of Poverty in Croatia. *Financial Theory and Practice*, 29 (1), str. 75-97.
10. Bejaković, P. (2009) Aktivnosti u odabranim zemljama u poticanju isplativosti rada. *Revija za socijalnu politiku*, 16(2), str. 159-174. doi: 10.3935/rsp.v16i2.838
11. Bejaković, P., Urban, I., Bezeredi, S., Matejina, A. (2012) Isplati li se raditi u Hrvatskoj? *Revija za socijalnu politiku*, 19(1), str. 83-92. doi: 10.3935/rsp.v19i1.1054.
12. Bejaković, P. (2013) The Importance of Social Transfers in Reducing Poverty in Croatia. *Economic Research-Ekonomska Istraživanja*, 26(1), str 103-116, https://doi.org/10.1080/1331677X.2013.11517642
13. Bejaković, P. (2016). Razvoj mjera aktivne politike zapošljavanja u Hrvatskoj i njihova evaluacija. *Revija za socijalnu politiku*, 23(2), str. 285-294. https://doi.org/10.3935/rsp.v23i2.1361
14. Bejaković, P. (2017) Poverty Alleviation: The Case of Croatia. In Staicu, G., ed., *Poverty, Inequality and Policy*, str. 63-80. DOI: 10.5772/intechopen.69197
15. Bejaković, P. (2018) Mjere za ublažavanje dugotrajne nezaposlenosti u Hrvatskoj. *Političke analize*, 9 (33-34), str. 36-43.
16. Bezeredi, S. i Urban, I. (2016). Predicting gross wages of non-employed persons in Croatia. *Financial Theory and Practice*, 40 (1), str. 1-61.
17. Bezeredi, S. et al. (2019) Making work pay in Croatia: an ex-ante evaluation of two in-work benefits using miCROmod. *International Journal of Microsimulation*, 12(3), str. 28-61. DOI: https://doi.org/10.34196/ijm.00206

18. Bezeredi, S. (2019) Utjecaj reformi poreza i socijalnih naknada na isplativost rada u Hrvatskoj od 2013. do 2018. *Ekonomska misao i praksa*, (2), str. 167-192.

19. Björklund, A. i Holmlund, B. (1991) The economics of unemployment insurance: the case of Sweden. U: Björklund, A., Haveman, R., Hollister, R., Holmlund, B., ur., *Labour Market Policy and Unemployment Insurance*, Oxford: Oxford University Press.

20. Blundell, R. i Macurdy, T. (1999) Labour supply: a review of alternative approaches. U: O. Ashenfelter and D. Card., ur., *Handbook of Labor Economics, Volume 3*, First edition, Amsterdam: Elsevier Science B.V.

21. Blundell R. (2000) Work incentives and 'in-work' benefit reforms: a review. *Oxford Review of Economic Policy*, 16(1), str. 27–44, https://doi.org/10.1093/oxrep/16.1.27

22. Blundell, R. i Hoynes, H. (2004) Has in-work benefit reform helped the labour market? U: Blundell R, Card D, Freeman R., ur., *Seeking a Premier League Economy*, University of Chicago Press, Chicago, str. 411–460.

23. Blundell, R., Bozio, A. i Laroque, G. (2013). Extensive and intensive margins of labour supply: Work and working hours in the US, the UK and France. *Fiscal Studies*, Vol. 34, No. 1, str. 1-29. DOI: 0143-5671

24. Breunig, R. i Mercante, J. (2010) The Accuracy of Predicted Wages of the Non-Employed and Implications for Policy Simulations from Structural Labour Supply Models. *Economic Record*, 86(272), str. 49-70. doi: 10.1111/j.1475-4932.2009.00619.x

25. Brewer, M., Duncan, A., Shephard, A. i Suarez, M. J. (2006) Did working families tax credit work? The impact of in-work support on labour supply in Great Britain. *Labour Economics*, 13(6), str. 699-720.

26. Brewer, M., Saez, E. i Shephard, A. (2010) Means-testing and tax rates on earnings. U: Adam, S. et al. ur., *Dimensions of tax design*, str. 90-173. Oxford: Oxford University Press.

27. Browne, J., Neumann, D. i Pacifico, D. (2018) Benefit generosity and work incentives for recipients of disability benefits in 12 EU Member States. *OECD*. Dostupno na: https://taxben.oecd.org/tax-ben-resources/Benefit-generosity-and-work-incentives-for-disability-benefit-recipients.pdf

28. Burlacu, I., O'Donoghue, C. i Sologon, D. M. (2014) Hypothetical models, U: O'Donoghue, C. ur., *Handbook of Microsimulation Modelling*, Bingley: Emerald Group Publishing Limited, str. 23–46.

29. Cameron, A. C. i Trivedi, P. K. (2005) *Microeconometrics: methods and applications*. Cambridge; New York: Cambridge University Press. doi: 10.1017/CBO9780511811241

30. Carey, D. i Tchilinguirian, H. (2000) Average effective tax rates on capital, labour and consumption. *OECD Economics Department Working Paper*, no 258. Dostupno na: https://www.oecd-ilibrary.org/docserver/247874530426.pdf?expires=1579522754&id=id&accname=guest&checksum=D4F28530F9C4AE43AA38912FFCB2B70E

31. Carone, G. et al. (2004) Indicators of Unemployment and Low-Wage Traps: Marginal Effective Tax Rates on Employment Incomes. *OECD Social, Employment and Migration Working Papers*, No. 18, Paris: OECD Publishing, https://doi.org/10.1787/137550327778.

32. Carone, G. et al. (2009) Recent reforms of the tax and benefit systems in the framework of flexicurity. European Communities. *Occasional Papers, 43*. https://ec.europa.eu/economy_finance/publications/pages/publication14173_en.pdf

33. Collado, D. et al. (2017) The end of cheap talk about poverty reduction: the cost of closing the poverty gap while maintaining work incentives. *Euromod Working Paper Series, No. 15/17*. Dostupno na : https://www.iser.essex.ac.uk/research/publications/working-papers/euromod/em5-17.pdf

34. Collado, D. (2018) Financial work incentives and the longterm unemployed: the case of Belgium. *Euromod Working Paper Series, No. 1/18*. Dostupno na: https://www.euromod.ac.uk/sites/default/files/working-papers/em1-18.pdf

35. Cuberes, D. i Teignier, M. (2016). Aggregate Costs of Gender Gaps in the Labor Market: A Quantitative Estimate. *Journal of Human Capital*, 10(1), str. 1-32.

36. Daveri, F. i Tabellini, G., 2000. Unemployment, Growth and Taxation in Industrial Countries. *Economic Policy*, 15 (30), str. 49-104.

37. De Agostini, P. (2017). EUROMOD Country Report: UNITED KINGDOM (UK) 2014-2017. *Institute for Social and Economic Research*. Dostupno na: https://www.euromod.ac.uk/sites/default/files/country-reports/year8/Y8_CR_UK_Final.pdf

38. De Luca, G., Rossetti, C. i Vuri, D. (2014) In-work benefits for married couples: an ex-ante evaluation of EITC and WTC policies in Italy. *IZA Journal of Labor Policy*, 3, 23. https://doi.org/10.1186/2193-9004-3-23

39. Deskar-Škrbić, M., Drezgić, S. i Šimović, H. (2018). Tax policy and labour market in Croatia: Effects of tax wedge on employment. *Economic Research-Ekonomska Istraživanja*, 31(1), str. 1218–1227. doi:10.1080/1331677X.2018.1456359

40. Dolenc, P. i Vodopivec, M. (2005a) The tax wedge in Slovenia: international comparison and policy recommendations. *Financial Theory and Practice*, 29 (3), str. 229-243.

41. Dolenc, P. i Vodopivec, M. (2005b) Does work pay in Slovenia? *Financial Theory and Practice*, 29 (4), str. 341-362.

42. Dolenc, P. i Laporšek, S. (2010) Tax Wedge on Labour and its Effect on Employment Growth in the European Union. *Prague Economic Papers,* 19(4), str. 344-358. DOI: 10.18267/j.pep.381

43. Dolenc, P., Laporšek, S. i Šeparović, A. (2011) Does labour taxation affect unemployment? Croatian worker in international perspective. *Economic Research-Ekonomska Istraživanja*, 24(3), str. 86–101.

44. Državni zavod za statistiku [DZS] (2017) Rezultati Ankete o dohotku stanovništva u 2016. *Statistička izvješća*, 1609/2017, Zagreb.

45. Dušek, L., Kalíšková, K. i Münich, D. (2013) Distribution of Average, Marginal and Participation Tax Rates among Czech Taxpayers: Results from a TAXBEN Model. *Finance a úvěr-Czech Journal of Economics and Finance*, 63(6), str. 474-504

46. Eissa N., Hoynes H. (2004) Taxes and the labor market participation of married couples: the earned income tax credit. *Journal of Public Economics*, 88(9-10), str. 1931–1958.

47. Europska komisija (2010) *Europe 2020 – European strategy for smart, sustainable and inclusive growth*. Brussels: Europska komisija. Dostupno na:

http://ec.europa.eu/eu2020/pdf/COMPLET%20EN%20BARROSO%20%20%20007%20-%20Europe%202020%20-%20EN%20version.pdf

48. Europska komisija (2015) *The 2015 Ageing Report: Economic and budgetary projections for the 28 EU Member States (2013-2060)*. Brussels: Europska komisija. Dostupno na: http://ec.europa.eu/economy_finance/publications/european_economy/2015/pdf/ee3_en.pdf

49. Europska komisija (2017a) *Tematski informativni članak o europskom semestru: Žene na tržištu rada*. Brussels: Europska komisija. Dostupno na: https://ec.europa.eu/info/sites/info/files/file_import/european-semester_thematic-factsheet_labour-force-participation-women_hr.pdf

50. Europska komisija (2017b) *Tematski informativni članak o europskom semestru: Zaposlenost mladih*. Brussels: Europska komisija . Dostupno na: https://ec.europa.eu/info/sites/info/files/file_import/european-semester_thematic-factsheet_youth_employment_hr.pdf

51. Europska komisija (2017c) *Tematski informativni članak o europskom semestru: Socijalna uključenost*. Brussels: Europska komisija. Dostupno na: https://ec.europa.eu/info/sites/info/files/file_import/european-semester_thematic-factsheet_social_inclusion_hr.pdf

52. Europska komisija (2017d) *Tematski informativni članak o europskom semestru: Aktivne politike tržišta rada*. Brussels: Europska komisija. Dostupno na: https://ec.europa.eu/info/sites/info/files/file_import/european-semester_thematic-factsheet_active-labour-market-policies_hr.pdf

53. Figari, F. (2010) Can in-work benefits improve social inclusion in the southern European countries? *Journal of European Social Policy*, 20(4), str 301–315. DOI:10.1177/0958928710374375 http://esp.sagepub.com

54. Figari, F. (2015) From Housewives to Independent Earners: How the Tax System Can Help Women to Work in a Context of Strong Familialism. *Journal of Social Policy*, 44(1), str. 63-82. https://doi.org/10.1017/S0047279414000555

55. Gabik, R. i Paur, D. (2017) EUROMOD Country Report: SLOVAK REPUBLIC (SK) 2014-2017. *Institute for Social and Economic Research*, dostupno na: https://www.euromod.ac.uk/sites/default/files/country-reports/year8/Y8_CR_SK_Final.pdf

56. Galuščák K. i Pavel, J. (2012) Taxes and Benefits: Work Incentive Effects of Policies. *Finance a úvěr-Czech Journal of Economics and Finance*, 62(1), str. 27–43.

57. Gasior, K., Recchia, P. (2019) The Use of Hypothetical Household Data for Policy Learning: Comparative Tax–Benefit Indicators Using EUROMOD HhoT. *Journal of Comparative Policy Analysis: Research and Practice*. DOI: 10.1080/13876988.2019.1609784

58. Greene, W. H., 2008. *Econometric analysis*. Upper Saddle River, N. J.: Prentice Hall.

59. Gregurić, I. (2011) Europe 2020 – europska strategija za pametan, održiv i uključiv razvoj. *Revija za socijalnu politiku*, 18(1), str. 119-124. doi: 10.3935/rsp.v18i1.963

60. Heckman, J. J., (1976) The Common Structure of Statistical Models of Truncation, Sample Selection and Limited Dependent Variables and a Simple Estimator for Such Models. *Annals of Economic and Social Measurement*, 5(4), str. 475-492.

61. Heckman, J. J. (1979) Sample Selection Bias as a Specification Error. *Econometrica*, 47(1), str. 153-161. doi: 10.2307/1912352

62. Immervoll, H. i O'Donoghue, C. (2002a) Welfare Benefits and Work Incentives An Analysis of the Distribution of Net Replacement Rates in Europe using EUROMOD, a Multi-Country Microsimulation Model. *EUROMOD Working Paper No. EM4/01*. Dostupno na: https://www.iser.essex.ac.uk/research/publications/working-papers/euromod/em4-01.pdf

63. Immervoll, H. i O'Donoghue C. (2002b) What Difference does a Job Make? The Income Consequences of Joblessness in Europe. *Working Paper No. 57*, National University of Ireland Galway, Department of Economics.

64. Immervoll, H., Marianna, P. i D'Ercole, M. M. (2004). Benefit coverage rates and household typologies: Scope and limitations of tax-benefit indicators. *OECD Social, Employment and Migration Working Papers, 20*. https://doi.org/10.1787/081036000058

65. Immervoll, H., Kleven, H. J., Kreiner, C. T. i Saez, E. (2007) Welfare reform in European countries: a microsimulation analysis. *The Economic Journal*, 117: 516, str. 1-44.

66. Immervoll, H. (2009) Minimum-Income Benefits in OECD Countries: Policy Design, Effectiveness and Challenges. *OECD Social, Employment and Migration Working Papers No. 100*. Dostupno na: https://www.oecd-ilibrary.org/social-issues-migration-health/minimum-income-benefits-in-oecd-countries_218402763872

67. Immervoll, H. i Pearson, M. (2009) A good time for making work pay? Taking stock of in-work benefits and related measures across the OECD. *OECD Social, Employment and Migration Working Papers*, No.81, Paris: OECD publishing.

68. Jara, H. X. i Tumino, A. (2013) Tax-benefit systems, income distribution and work incentives in the European Union. *International Journal of Microsimulation*, 6(1), str. 27-62.

69. Jara, H. X. i Tumino, A. (2018) Income protection of atypical workers in the event of unemployment in Europe. *Euromod Working Paper Series, No. 18/18*. Dostupno na: https://www.euromod.ac.uk/sites/default/files/working-papers/em18-18.pdf

70. Jara, H. X., Gasior, K. i Makovec, M. (2019) Work incentives at the extensive and intensive margin in Europe: the role of taxes, benefits and population characteristics. *Euromod Working Paper Series, No. 19/19*. Dostupno na: https://www.euromod.ac.uk/sites/default/files/working-papers/em19-19.pdf

71. Kališkova, K. (2015) Tax and Transfer Policies and the Female Labor Supply in the EU. *IZA Discussion Paper No. 8949*, Bonn, Germany. Dostupno na: http://ftp.iza.org/dp8949.pdf

72. Kump, N., Čok, M., Majcen, B. (2018). EUROMOD Country Report: Slovenia 2015-2018. *Institute for Social and Economic Research*. Dostupno na: https://www.euromod.ac.uk/sites/default/files/country-reports/year9/Y9_CR_SI_Final.pdf

73. Kurowska, A., Myck, M. i Wrohlich, K. (2017) Making work pay: increasing labour supply of secondary earners in low income families with children. *Contemporary Economics*, 11(2), str. 161-170. DOI:10.5709/ce.1897-9254.234

74. Ladányi, T., Kierzenkowski, R. (2012). „Work Incentives and Recent Reforms of the Tax and Benefit System in Hungary". *OECD Economics Department Working Papers*, No. 944. http://dx.doi.org/10.1787/5k9d1969m56b-en

75. Laporšek, S., Vodopivec, M., Vodopivec, M. (2019) Making work pay in Slovenia. *Revija za socijalnu politiku*, 26(3), str. 315-337.

76. Layard, R., Nickell, S. i Jackman R. (1991) *Unemployment: Macroeconomic performance and the labour market*, Oxford: Oxford University Press.

77. Lehmann, E., Lucifora, C., Moriconi, S. i Van der Linden, B. (2016) Beyond the labour income tax wedge: The unemployment-reducing effect of tax progressivity. *International Tax and Public Finance*, 23(3), str. 454–489. doi:10.1007/s10797-015-9377-9.

78. Leppik, L. (2006) In-work benefits: literature review. *PRAXIS Center for Policy Studies*. Dostupno na: http://siteresources.worldbank.org/INTECONEVAL/Resources/IWBliteratureReviewFinal.pdf

79. Lietz C. i Mantovani D. (2007) A short introduction to EUROMOD: an integrated European tax-benefit model. U: Bargain, O., ur., *Micro-Simulation in Action: Policy Analysis in Europe using EUROMOD, Research in Labor Economics,* 25, str. 1-16.

80. Maddala, G.,S. (2001) *Introduction to Econometrics*, Chichester: John Wiley & Sons.

81. Marx, I., Vanhille, J. i Verbist, G. (2012) Combating in-work poverty in continental Europe: an investigation using the Belgian case. *Journal of Social Policy*, 41(1), str. 19-41.

82. Matsaganis, M. i Figari, F. (2016). Making work pay: A conceptual paper (Research note No. 3/2016). *Research note,* European Commission.

83. McKnight, A. et al. (2016) Low pay and in-work poverty: preventative measures and preventative approaches, *Evidence Review*, European Commission.

84. Mrnjavac, Ž. i Blažević, S. (2014) Is minimum wage a good policy for poor workers in Croatia?. *Management*, 19 (1), str. 17-43.

85. Myck, M. et al. (2015) Financial incentives to work in the context of a complex reform package and growing wages: The Polish experience 2005–2011. *Baltic Journal of Economics*, 15(2), str. 99–121. doi:10.1080/1406099X.2015.1124227

86. Navicke, J. i Lazutka, R. (2016) Work incentives across the income distribution and for model families in Lithuania: 2005-2013. *Baltic Journal of Economics*, 16 (2), str. 175-191. DOI: 10.1080/1406099X.2016.1205407.

87. Nestić, D. i Blažević Burić, S. (2018). Radnici na minimalnoj plaći i siromaštvo u Hrvatskoj. *Revija za socijalnu politiku*, 25 (3), str. 235-262. https://doi.org/10.3935/rsp.v25i3.1547

88. Nestić, D. i Tomić, I. (2018) Jobless Population and Employment Flows in Recession. *Journal of Balkan and Near Eastern Studies*, 20(3), str. 273–292. https://doi.org/10.1080/19448953.2018.1385271

89. O'Donoghue, C. (2011) Do tax-benefit systems cause high replacement rates? A decompositional analysis using EUROMOD. *LABOUR*, 25(1), str. 126–151.

90. OECD (2005) OECD Employment Outlook 2005, *OECD Publishing*, Paris, https://doi.org/10.1787/empl_outlook-2005-en.

91. OECD (2011) Taxation and Employment, *OECD Tax Policy Studies*, No. 21, OECD Publishing. http://dx.doi.org/10.1787/9789264120808-en.

92. Owens, J. (2006) Fundamental tax reform: an international perspective. *National Tax Journal*, 59(1), str. 131–164.

93. Pearson, M. (2002) International experience of „making work pay policies“. *Working Paper OECD*.

94. Ranđelović, S. i Žarković-Rakić, J. (2013) Improving work incentives in Serbia: evaluation of a tax policy reform using SRMOD. *International Journal of Microsimulation*, Vol. 6, No. 1, str. 157-176.

95. Rismondo, M. (2010) Hrvatski sustav mirovinskog osiguranja i europski socijalni model. *Revija za socijalnu politiku*, 17 (1), str. 89-112.

96. Saez, E. (2002) Optimal Income Transfer Programs: Intensive versus Extensive Labor Supply Responses. *The Quarterly Journal of Economics*, 117 (3), str. 1039-1073.

97. Snower, D. J., (1997) Evaluating unemployment policies: What do the underlying theories tell us?. U: Snower, D. J. i De La Dehesa, G., ur., *Unemployment policy: Government options for the labour market*. Cambridge: Cambridge University Press. str. 15-53.

98. Steiner, V. i Wrohlich, K. (2005) Work incentives and labour supply effects of the mini-jobs reform in Germany. *Empirica*, 32, str. 91–116.

99. Sutherland, H., Figari, F. (2013) EUROMOD: the European Union tax-benefit microsimulation model. *International Journal of Microsimulation*, 6(1), str. 4-26.

100. Šeparović, A. (2009) The influence of the tax wedge on unemployment in OECD countries in comparison with Croatia. *Financial Theory and Practice*, 33(4), str. 449–463.

101. Šućur, Z. et al. (2016) Struktura naknada, izdaci i korisnici programa socijalne zaštite u Republici Hrvatskoj. Ministarstvo socijalne politike i mladih. https://bib.irb.hr/prikazi-rad?&rad=807966 ˙(accessed 10 February 2018).

102. Tomić, I. (2015) Zaposlenost i nezaposlenost u Hrvatskoj – stanje, trendovi i okruženje. U: Vidović D., ur., *Zaposlimo Hrvatsku! Strateške smjernice za rast zaposlenosti,* Zagreb: Hrvatska gospodarska komora, str. 21-42. Dostupno na: http://predsjednica.hr/files/zaposlimo_hrvatsku_publikacija.pdf

103. Urban, I., (2016) Primjena mikrosimulacijskih modela u analizi poreza i socijalnih naknada u Hrvatskoj. *Newsletter No. 104.*, Zagreb: Institute of Public Finance.

104. Urban, I., Bezeredi, S., Pezer, M. (2018a) EUROMOD Country Report: Croatia 2014-2018. *Institute for Social and Economic Research.* Dostupno na: https://www.euromod.ac.uk/sites/default/files/country-reports/year9/Y9_CR_HR_Final.pdf.

105. Urban, I., Pezer, M., Bezeredi, S. (2018b) *miCROmod report: 2014-2017*. Zagreb: Institute of Public Finance.

106. Urban, I., Čok, M., Verbič, M. (2019) The burden of labour taxation in Croatia, Slovenia and Slovakia in the period 2011-2017. *Economic Research-Ekonomska Istraživanja*, 32(1), str. 1430-1456. DOI: 10.1080/1331677X.2019.1638291.

107. Vandelannoote, D. i Verbist, G. (2020). The impact of in-work benefits on work incentives and poverty in four European countries. *Journal of European Social Policy*, https://doi.org/10.1177/0958928719891314.

108. Vlada RH (2018). *Nacionalni program reformi 2018*. Dostupno na: https://ec.europa.eu/info/sites/info/files/2018-european-semester-national-reform-programme-croatia-hr.pdf

109. Vodopivec, M. (2004) Income Support for the Unemployed. *Issues and Options. World Bank, Regional and Sectoral Studies*, Washington. Dostupno na: http://documents.worldbank.org/curated/en/857941468778794616/pdf/298930PAPER0In1pport0for0unemployed.pdf

110. Wooldridge, J. (2002) *Econometric Analysis of Cross Section and Panel Data*. Second Edition. Cambridge: MIT Press.

POPIS TABLICA I SLIKA

Popis tablica

Tablica 2.1. Komponente izdataka u sustavu socijalne zaštite u 2017, u % BPD-a 28
Tablica 3.1. Fleksibilne i nefleksibilne osobe u Hrvatskoj 52
Tablica 3.2. Podjela fleksibilnih žena prema statusu aktivnosti u Hrvatskoj 53
Tablica 3.3. Podjela fleksibilnih muškaraca prema statusu aktivnosti u Hrvatskoj 53
Tablica 3.4. Distribucija fleksibilnih parova prema statusu zaposlenja u Hrvatskoj 53
Tablica 3.5. Distribucija fleksibilnih pojedinaca prema statusu zaposlenja u Hrvatskoj 53
Tablica 3.6. Fleksibilne i nefleksibilne osobe u Sloveniji 54
Tablica 3.7. Podjela fleksibilnih žena prema statusu aktivnosti u Sloveniji 54
Tablica 3.8. Podjela fleksibilnih muškaraca prema statusu aktivnosti u Sloveniji 55
Tablica 3.9. Distribucija fleksibilnih parova prema statusu zaposlenja u Sloveniji 55
Tablica 3.10. Distribucija fleksibilnih pojedinaca prema statusu zaposlenja u Sloveniji 55
Tablica 3.11. Opis varijabli korištenih u Heckmanovom modelu za predviđanje plaće 56
Tablica 3.12. Deskriptivna statistika varijabli korištenih u Heckmanovom selekcijskom modelu za Hrvatsku 57
Tablica 3.13. Procjena logaritma bruto plaće po satu Heckmanovim selekcijskim modelom za Hrvatsku 58
Tablica 3.14. Distribucija predviđenih plaća za neaktivne i nezaposlene osobe u Hrvatskoj (u kn) 60
Tablica 3.15. Deskriptivna statistika varijabli korištenih u Heckmanovom selekcijskom modelu za Sloveniju 61
Tablica 3.16. Procjena logaritma bruto plaće po satu Heckmanovim selekcijskim modelom za Sloveniju 61
Tablica 3.17. Distribucija predviđenih plaća za neaktivne i nezaposlene osobe u Sloveniji (u EUR) 63
Tablica 4.1. Trajanje prava na naknadu za nezaposlene u Hrvatskoj, 2017. 66
Tablica 4.2. Mjesečni iznosi sredstava za uzdržavanje po članu u Hrvatskoj, 2017. 67
Tablica 4.3. Pragovi i iznosi dječjeg doplatka po djetetu u Hrvatskoj, 2017. 68
Tablica 4.4. Mjesečni iznosi osobnih odbitaka u Hrvatskoj, 2017. 68
Tablica 4.5. Porezni razredi u Hrvatskoj, 2017. 69
Tablica 4.6. Distribucija PPS-a prema određenim demografskim karakteristikama u Hrvatskoj (u %) 79
Tablica 4.7. Procjena vjerojatnosti vrlo visokog PPS-a u Hrvatskoj logit modelom 80
Tablica 4.8. Dekompozicija PPS-a prema različitim podskupinama u Hrvatskoj 82
Tablica 4.9. Trajanje prava na naknadu za nezaposlene u Sloveniji, 2017. 83
Tablica 4.10. Mjesečni iznosi osnovnog minimalnog dohotka u Sloveniji, 2017. 84

Tablica 4.11. Mjesečni iznosi procijenjene neprofitne najamnine prema strukturi kućanstva u Sloveniji, 2017. 85
Tablica 4.12. Pragovi i iznosi dječjeg doplatka po djetetu u Sloveniji, 2017. (u EUR) 85
Tablica 4.13. Stope doprinosa iz plaće u Sloveniji, 2017. 86
Tablica 4.14. Godišnji iznosi osobnih odbitaka u Sloveniji, 2017. (u EUR) 86
Tablica 4.15. Porezni razredi u Sloveniji, 2017. 86
Tablica 4.16. Distribucija PPS-a prema određenim demografskim karakteristikama u Sloveniji (u %) 96
Tablica 4.17. Procjena vjerojatnosti vrlo visokog PPS-a u Sloveniji logit modelom 97
Tablica 4.18. Dekompozicija PPS-a prema različitim podskupinama u Sloveniji 98
Tablica 4.19. Komparativna analiza distribucije PPS-a između Hrvatske i Slovenije (u %)101
Tablica 4.20. Komparativna analiza distribucije NSZ-a između Hrvatske i Slovenije (u %) 104
Tablica 5.1. Godišnji iznos elemenata za simulaciju naknada za zaposlene u Hrvatskoj (u kn) 108
Tablica 5.2. Distribucija uvođenja naknade za zaposlene među kućanstvima u Hrvatskoj, agregatni pokazatelji 116
Tablica 5.3. Utjecaj uvođenja naknade na stopu siromaštva u Hrvatskoj 119
Tablica 5.4. Utjecaj uvođenja naknade na stopu siromaštva zaposlenih osoba u Hrvatskoj (u %) 120
Tablica 5.5. Distribucija naknada za zaposlene prema odabranim tipovima fleksibilnih osoba u Hrvatskoj, (u %) 121
Tablica 5.6. Distribucija participacijske porezne stope nakon uvođenja naknada za zaposlene u Hrvatskoj (u %) 124
Tablica 5.7. Godišnji iznos elemenata za simulaciju naknada za zaposlene u Sloveniji (u EUR) 126
Tablica 5.8. Distribucija uvođenja naknade za zaposlene među kućanstvima u Sloveniji, agregatni pokazatelji 134
Tablica 5.9. Utjecaj uvođenja naknade na stopu siromaštva u Sloveniji 136
Tablica 5.10. Utjecaj uvođenja naknade na stopu siromaštva zaposlenih osoba u Sloveniji (u %) 137
Tablica 5.11. Distribucija naknada za zaposlene prema odabranim tipovima fleksibilnih osoba Sloveniji, (u %) 138
Tablica 5.12. Distribucija participacijske porezne stope nakon uvođenja naknada za zaposlene u Sloveniji (u %) 140
Tablica 5.13. Komparativna analiza utjecaja naknada za zaposlene na PPS u Hrvatskoj i Sloveniji za odabrane tipove kućanstva u kojima se promatrani član zapošljava uz minimalnu bruto plaću 142
Tablica 5.14. Komparativna analiza utjecaja naknada za zaposlene na distribuciju PPS-a u Hrvatskoj i Sloveniji (u %) 144

Popis slika

Slika 2.1. Stopa aktivnosti u 2017. za populaciju u dobi od 20 do 64 godine prema spolu, % 16

Slika 2.2. Stopa zaposlenosti u 2017. za populaciju od 20 do 64 godine prema spolu, % 18

Slika 2.3. Stopa zaposlenosti u 2017. za populaciju od 20 do 64 godine prema stupnju obrazovanja, %..... 19

Slika 2.4. Stopa nezaposlenosti u 2017. za populaciju od 20 do 64 godine prema spolu, % 20

Slika 2.5. Udio dugotrajne i vrlo dugotrajne nezaposlenosti u ukupnoj nezaposlenosti u 2017. za populaciju od 20 do 64 godine, % 21

Slika 2.6. Kretanje udjela dugotrajne i vrlo dugotrajne stope nezaposlenosti u ukupnoj stopi nezaposlenosti u Hrvatskoj kroz godine za populaciju od 20 do 64 godine, % 22

Slika 2.7. Stopa dugotrajne i vrlo dugotrajne nezaposlenosti u 2017. za populaciju od 20 do 64 godine, % 23

Slika 2.8. Struktura neaktivne populacije u 2017. za populaciju od 20 do 64 godine, % 24

Slika 2.9. Udio nezaposlenih i potencijalno zapošljivih neaktivnih osoba u 2017. za populaciju od 20 do 64 godine u Hrvatskoj, %..... 25

Slika 2.10. Potencijalna radna snaga u 2017. za populaciju od 20 do 64 godine, % 26

Slika 2.11. Ukupni izdatci za programe socijalne zaštite u 2017., % BDP-a 27

Slika 2.12. Stopa rizika od siromaštva u 2017. prema spolu, %..... 29

Slika 2.13. Stopa rizika od siromaštva u 2017. prema najčešćem statusu aktivnosti, %..... 30

Slika 4.1. PPS i raspoloživi dohodak samaca i samohranih roditelja s dvoje djece, Hrvatska 2017. 71

Slika 4.2. PPS i raspoloživi dohodak parova bez djece i s dvoje djece u kojima prvi supružnik razmatra zaposlenje, a drugi ne radi, Hrvatska 2017. 72

Slika 4.3. PPS i raspoloživi dohodak parova bez djece i s dvoje djece u kojima prvi supružnik razmatra zaposlenje, a drugi je već zaposlen uz bruto plaću od 75% PBP-a, Hrvatska 2017.. 74

Slika 4.4. Dekompozicija PPS-a u Hrvatskoj za 2017. na razinama plaća od: (a) 40% PBP-a; (b) 67% PBP-a; (c) 100% PBP-a..... 77

Slika 4.5. PPS i raspoloživi dohodak samaca i samohranih roditelja s dvoje djece, Slovenija 2017. 88

Slika 4.6. PPS i raspoloživi dohodak parova bez djece i s dvoje djece u kojima prvi supružnik razmatra zaposlenje, a drugi ne radi, Slovenija 2017. 90

Slika 4.7. PPS i raspoloživi dohodak parova bez djece i s dvoje djece u kojima prvi supružnik razmatra zaposlenje, a drugi je već zaposlen uz bruto plaću od 75% PBP-a, Slovenija 2017. 92

Slika 4.8. Dekompozicija PPS-a u Sloveniji u 2017. na razinama plaća od: (a) 50% PBP-a; (b) 67% PBP-a; (c) 100% PBP-a 94

Slika 4.9. Komparativna analiza PPS-a između Hrvatske i Slovenije u 2017. za odabrane tipove kućanstva na razinama plaća od: (a) 50% PBP-a; (b) 67% PBP-a; (c) 100% PBP-a 100

Slika 4.10. Komparativna analiza NSZ-a između Hrvatske i Slovenije u 2017. za odabrane tipove kućanstva na razinama plaća od: (a) 50% PBP-a; (b) 67% PBP-a; (c) 100% PBP-a.. 103

Slika 5.1. Godišnji iznosi naknade za zaposlene WTC-FAM u Hrvatskoj (kn) 109

Slika 5.2. Godišnji iznosi naknada za zaposlene WTC-IND i ETC-IND u Hrvatskoj (kn)... 110
Slika 5.3. Raspoloživi dohodak različitih tipova kućanstava s obzirom na uvedene politike za povećanje isplativosti rada u Hrvatskoj ... 112
Slika 5.4. Distribucija PPS-a za različite tipove kućanstava s obzirom na uvedene politike za povećanje isplativosti rada u Hrvatskoj ... 114
Slika 5.5. Povećanje raspoloživog dohotka kućanstva u Hrvatskoj u odnosu na osnovni scenarij (%) ... 117
Slika 5.6. Primatelji naknade za zaposlene prema kvintilnim skupinama kućanstava u Hrvatskoj ... 117
Slika 5.7. Godišnji iznosi naknade za zaposlene WTC-FAM u Sloveniji, EUR ... 127
Slika 5.8. Godišnji iznosi naknade za zaposlene WTC-IND u Sloveniji, EUR ... 127
Slika 5.9. Raspoloživi dohodak različitih tipova kućanstava s obzirom na uvedene politike za povećanje isplativosti rada u Sloveniji ... 130
Slika 5.10. Distribucija PPS-a za različite tipove kućanstava s obzirom na uvedene politike za povećanje isplativosti rada u Sloveniji ... 132
Slika 5.11. Povećanje raspoloživog dohotka kućanstava u Sloveniji u odnosu na osnovni scenarij (%) ... 134
Slika 5.12. Primatelji naknade za zaposlene prema kvintilnim skupinama kućanstava u Sloveniji ... 135

POPIS KRATICA

ADS	Anketa o dohotku stanovništva
EITC	Politika za povećanje isplativosti rada uvedena u SAD-u; engl. *Earned Income Tax Credit*
ETC	Politika za povećanje isplativosti rada uvedena u Slovačkoj; engl. *Employee tax credit*
EU	Europska unija
NSZ	Neto stopa zamjene; engl. *net replacement rate*
OECD	Organizacija za ekonomsku suradnju i razvoj; engl. *Organisation for Economic Cooperation and Development*
PPS	Participacijska porezna stopa; engl. *participation tax rate*
SAD	Sjedinjene Američke Države
UK	Ujedinjeno Kraljevstvo
WFTC	Politika za povećanje isplativosti rada uvedena u UK-u; engl. *Working Family Tax Credit*

ŽIVOTOPIS

Slavko Bezeredi rođen je 1987. godine u Zagrebu. Osnovnoškolsko obrazovanje završio je u Zagrebu gdje je i maturirao 2002. godine u Srednjoj školi Sesvete, smjer tehničar za računalstvo. Godine 2009. na Prirodoslovno matematičkom fakultetu – Matematičkom odsjeku Sveučilišta u Zagrebu stječe titulu prvostupnika matematike. Nakon toga, na istom fakultetu upisuje diplomski studij „Financijska i poslovna matematika“ koji je završio 2011. i stekao titulu magistra matematike. Godine 2015. zaršio je poslijediplomski specijalistički studij „Statističke metode za ekonomske analize i prognoziranje“na Ekonomskom fakultetu Sveučilišta u Zagrebu. Svoju istraživačku karijeru započeo je u Institutu za javne financije u listopadu 2011. Od rujna 2016. do rujna 2017. radio je kao suradnik na Marie Curie IAPP projektu na Sveučilištu u Sheffieldu. U sklopu ljetnih škola usavršavao se na Barcelona Graduate School of Economics, te na Sveučilištu u Essexu i Zagrebu. Njegovo uže područje interesa su mikrosimulacije poreza i socijalnih naknada, analiza politika za povećanje isplativosti rada i neformalna ekonomija.

Odabrani istraživački projekti:

- 2020. – 2024. Utjecaj poreza i socijalnih naknada na raspodjelu dohotka i ekonomsku efikasnost (ITBIDEE); financira: Hrvatska zaklada za znanost, oznaka: IP-2019-04-9924.
- 2015. – 2018. Primjena mikrosimulacijskih modela u analizi poreza i socijalnih naknada u Hrvatskoj (status: završen; predmet istraživanja: mikrosimulacije i analiza poreza i socijalnih naknada; financirala: Hrvatska zaklada za znanost, oznaka: UIP-2014-09-4096).
- Od 2013. EUROMOD Hrvatska (status: u tijeku; predmet istraživanja: ažuriranje modela s novim podacima i parametrima sustava poreza i socijalnih naknada; financira: University of Essex).
- 2013. – 2017 Izlazak iz sjene, razvoj kapaciteta i sposobnosti za suzbijanje neprijavljenog rada u Bugarskoj, Hrvatskoj i Makedoniji (FP7 sedmi okvirni program za istraživanje, tehnološki razvoj i demonstracijske aktivnosti EU Marie Curie Industry-Academia Partnerships and Pathways (IAPP) grant no. 611259; status: završen; predmet istraživanja: neprijavljeni rad; financirala: Europska komisija).

Popis objavljenih radova

Bezeredi, S., Ledić, M., Rubil, I. i Urban, I. (2019) Making work pay in Croatia: An ex-ante evaluation of two in-work benefits using miCROmod. *International Journal of Microsimulation*, 12(3), 28-61. https://doi.org/10.34196/ijm.00206

Bezeredi, S. (2019) Utjecaj reformi poreza i socijalnih naknada na isplativost rada u Hrvatskoj od 2013. do 2018. *Ekonomska misao i praksa*, (2), 167-192.

Bejaković, P. i Bezeredi, S. (2019). Determinants of Tax Morale in Croatia: an Ordered Logit Model. *Business Systems Research*, 10(2), 37-48. doi: 10.2478/bsrj-2019-016

Williams, C. C. i Bezeredi, S. (2018) Explaining informal entrepreneurship in South-East Europe: a tax morale approach. *Eastern Journal of European Studies*, 9(2), 47-68.

Williams, C. C. i Bezeredi, S. (2018) Explaining and tackling under-declared employment in FYR Macedonia: the employers perspective. *The South East European Journal of Economics and Business*, 13(2), 19-31. doi: 10.2478/jeb-2018-0010

Williams, C. C. i Bezeredi, S. (2018) An institutional theory of informal entrepreneurship: some lessons from FYR Macedonia. *Journal of Developmental Entrepreneurship*, 23(3). doi: 10.1142/S108494671850019X

Pezer, M., Bezeredi, S. i Leventi, C.(2018) The distributional impact of local social benefits of Zagreb, Split, Rijeka and Osijek. *Proceedings of 7th International Scientific Symposium „Economy of eastern Croatia - vision and growth"*, 582-590.

Williams, C. C. i Bezeredi, S. (2018) Explaining and tackling the informal economy: a dual informal labour market approach. *Employee Relations*, 40(5), 889-902.

Williams, C. C. i Bezeredi, S. (2017) Explaining Consumers' Motives for Purchasing from the Informal Economy: Some Lessons from a Study of Bulgaria, Croatia and FYR of Macedonia. *Economic Alternatives*, 4, 515-531.

Williams, C. C. i Bezeredi, S. (2017) Evaluating the use of personal connections to bypass formal procedures: a study of vrski in Republic of Macedonia. *UTMS Journal of Economics*, 8(2), 169-182.

Williams, C. C. i Bezeredi, S. (2017) Tackling the Illegal practice of under-reporting employees' wages: lessons from the Republic of Macedonia. *UTMS Journal of Economics*, 8(3), 243–258.

Bezeredi, S. i Urban, I. (2016) Predicting gross wages of non-employed persons in Croatia. *Financial Theory and Practice*, 40(1), 1-61.

Urban, I. i Bezeredi, S. (2014) Promjene u Zakonu o porezu na dohodak: utjecaj na prosječnu poreznu stopu. *Aktualni osvrti*, br. 71.

Bezeredi, S. (2012) Utjecaj promjena u porezu na dohodak na porezni teret građana. *Newsletter*, br. 68.

Bejaković, P., Urban, I., Bezeredi, S. i Matejina, A. (2012) Isplati li se raditi u Hrvatskoj? *Revija za socijalnu politiku*, 19 (1), 82-92.