Sufinansira Evropska unija

MINISTRY OF FOREIGN AFFAIRS OF DENMARK

Švedska Sverige

UJEDINJENE NACIJE BOSNA I HERCEGOVINA

U parnerstvu sa: gef EQUANOMICS

OTKRIVANJE RODNE RAZLIKE U PLATAMA U BOSNI I HERCEGOVINI -

DOKAZI IZ PRILAGOĐENIH MODELA ZARADE



UN WOMEN FOR ALL WOMEN AND GIRLS

UNITED NATIONS DEVELOPMENT PROGRAMME

UNFPA

unicef for every child

IMPRESUM

Otkrivanje rodne razlike u platama u Bosni i Hercegovini - Dokazi prilagođenih modela zarade

Autor:

Adnan Efendić, PhD - *Redovni profesor ekonomije i rukovodilac Katedre za ekonomsku teoriju i politiku, Ekonomski fakultet Univerziteta u Sarajevu.*

Koordinatori istraživanja:

Aldin Međedović, PhD - *Projektni menadžer, Razvojni program Ujedinjenih nacija (UNDP) u Bosni i Hercegovini.*

Nera Monir Divan - *Savjetnica za rodnu ravnopravnost i inkluziju, Razvojni program Ujedinjenih nacija (UNDP) u Bosni i Hercegovini.*

Stručni pregled:

Samra Filipović-Hadžiabdić - *Direktorica Agencije za ravnopravnost spolova Bosne i Hercegovine, Ministarstvo za ljudska prava i izbjeglice Bosne i Hercegovine.*

Nera Monir Divan - *Savjetnica za rodnu ravnopravnost i inkluziju, Razvojni program Ujedinjenih nacija (UNDP) u Bosni i Hercegovini.*

Aldin Međedović, PhD - *Projektni menadžer, Razvojni program Ujedinjenih nacija (UNDP) u Bosni i Hercegovini.*

Saša Leskovac, PhD - *Stručni savjetnik, Agencija za ravnopravnost spolova Bosne i Hercegovine, Ministarstvo za ljudska prava i izbjeglice Bosne i Hercegovine.*

Raduška Cupać - *Voditeljica Sektora za energiju i okoliš, Razvojni program Ujedinjenih nacija (UNDP) u Bosni i Hercegovini.*

Aida Laković-Hošo - *Voditeljica Sektora za efikasno upravljanje, Razvojni program Ujedinjenih nacija (UNDP) u Bosni i Hercegovini.*

Ova studija izrađena je u okviru Zajedničkog programa „Akcelerator rodne ravnopravnosti“ (Gender Equality Accelerator- GEA), koji provode agencije Ujedinjenih nacija u Bosni i Hercegovini: UN Women, UNDP, UNFPA i UNICEF, uz finansijsku podršku Evropske unije i vlada Danske i Švedske, u saradnji s Agencijom za ravnopravnost spolova Bosne i Hercegovine, Gender centrom Federacije Bosne i Hercegovine i Centrom za jednakost i ravnopravnost polova Republike Srpske.

Ova publikacija izrađena je u partnerstvu s Agencijom za ravnopravnost spolova Bosne i Hercegovine, koja djeluje u okviru Ministarstva za ljudska prava i izbjeglice Bosne i Hercegovine, u okviru „Foruma žena za razvoj“ (Women Forum for Development – WF4D[1]). Studija donosi proširenu analizu prilagođenog rodnog jaza u platama u Bosni i Hercegovini, nadopunjujući prateći zbornik „Više od brojeva: Rodna ravnopravnost, liderstvo, rad i ekonomska sigurnost u Bosni i Hercegovini“. Analizira faktore koji doprinose rodnom jazu u prihodima te jača bazu dokaza za dijalog o javnim politikama i djelovanje usmjereno na smanjenje rodnog jaza u platama i unapređenje ekonomske ravnopravnosti žena u Bosni i Hercegovini. Publikacija je također izrađena u saradnji s UNDP-ovim projektom „Peta nacionalna komunikacija o klimatskim promjenama u Bosni i Hercegovini“ (5NC[2]) koji se provodi uz podršku Globalnog fonda za okoliš (GEF).

Stavovi izneseni u ovoj publikaciji stavovi su autora i ne odražavaju nužno stavove Ujedinjenih nacija ili njihovih država članica, agencija koje provode program (UN Women, UNDP, UNFPA i UNICEF), niti partnera koji doprinose njegovoj realizaciji (Evropska unija, Švedska, Danska), niti Agencije za ravnopravnost spolova Bosne i Hercegovine, Gender centra Federacije Bosne i Hercegovine, Centra za jednakost i ravnopravnost polova Republike Srpske, Globalnog fonda za okoliš, Foruma žena za razvoj niti UNDP-ove globalne inicijative EQUANOMICS.

1 www.wf4d.ba

2 Puni naziv projekta 5NC glasi: *„Development of the First Biennial Transparency Report of Bosnia and Herzegovina and the Fifth National Communication and Second Biennial Transparency Report as a Combined Report under the UNFCCC (BTR1–NC5/BTR2)“*

OTKRIVANJE RODNE RAZLIKE U PLATAMA U BOSNI I HERCEGOVINI -

DOKAZI IZ PRILAGOĐENIH MODELA ZARADE

Sarajevo, oktobar 2026.

PREDGOVOR

Ekonomsko učešće žena od suštinskog je značaja za inkluzivni rast, ali sam pristup zaposlenju ne garantuje jednake mogućnosti, pravednu zaradu niti ekonomsku sigurnost. Da bismo u Bosni i Hercegovini razumjeli šta stoji na putu ostvarivanja tih ciljeva, potrebno je sagledati više od zbirnih pokazatelja i ispitati strukturne okolnosti koje oblikuju iskustva žena na tržištu rada.

Ova studija daje važan doprinos tom razumijevanju pokazujući da se rodna razlika u platama dodatno izražava kada se uzmu u obzir razlike u mjerljivim karakteristikama žena i muškaraca. Nalazi potvrđuju potrebu da se ne bavimo samo razlikama u platama već i širim preprekama povezanim s obavezama njege i brige, društvenim normama, rodnom segregacijom u zanimanjima i nejednakim pristupom mogućnostima.

Izrađena u okviru Zajedničkog programa Akcelerator rodne ravnopravnosti (GEA), projekta 5NC koji uz GEF podršku implementira UNDP i inicijative Equanomics Lab koju provodi UNDP, ova publikacija pokazuje vrijednost saradnje između različitih sektora, institucija i naučnih disciplina. Nijedna oblast javnih politika niti jedna organizacija ne može samostalno odgovoriti na ove međusobno povezane izazove. Napredak zahtijeva koordinirano djelovanje u oblastima ekonomske politike, institucija tržišta rada, sistema njege i brige, obrazovanja i privatnog sektora, utemeljeno na dokazima i stvarnim iskustvima žena.

Na ove izazove dodatno utiču klimatske promjene te zelena i digitalna tranzicija, koje mijenjaju tržište rada i stvaraju nove mogućnosti, ali i rizike od produbljivanja postojećih neravnopravnosti. Kako bi žene imale pristup novim zelenim poslovima, razvijale potrebne vještine i ravnopravno koristile prednosti novih investicija, neophodne su koordinirane rodno odgovorne politike koje povezuju zapošljavanje, brigu i staranje, socijalnu zaštitu i inkluzivno donošenje odluka. Integrisanje rodne ravnopravnosti u klimatske politike i ekonomsku transformaciju stoga je ključno za pravednu zelenu tranziciju i osiguravanje da rezultati razvoja budu dostupni svima, ne ostavljajući nikoga po strani, te za održivi humani razvoj Bosne i Hercegovine.

Ova studija predstavlja proširenu verziju jedne od tema obrađenih u sveobuhvatnijem zborniku, objavljenom paralelno s ovom publikacijom. Zajedno, ove dvije komplementarne publikacije nude različite perspektive o izazovima i faktorima koji omogućavaju veće učešće žena na tržištu rada i unapređuju njihovu ekonomsku sigurnost u Bosni i Hercegovini. Zajednički cilj im je jačanje baze dokaza za kreiranje javnih politika koje opredjeljenja za rodnu ravnopravnost pretvaraju u mjerljive promjene.

Zadatak pred nama je jasan: osigurati da žene mogu učestvovati na tržištu rada, napredovati i biti pravično plaćene, te da održivi humani razvoj Bosne i Hercegovine koristi puni potencijal svih njenih građanki i građana.

Renaud Meyer
Rezidentni predstavnik
Razvojni program Ujedinjenih nacija

Samra Filipović-Hadžiabdić
Direktorica
Agencija za ravnopravnost spolova,
Ministarstvo za ljudska prava i izbjeglice
Bosne i Hercegovine

SAŽETAK

Ova studija ispituje rodnu razliku u platama (RRP - eng. GPG) koristeći primarne podatke prikupljene u Bosni i Hercegovini za UNDP-ov Barometar rodne ravnopravnosti 2024. Studija analizira i neprilagođene rodne razlike u zaradama i prilagođene rodne razlike u platama, uzimajući u obzir uočljive individualne karakteristike i karakteristike tržišta rada. Empirijska analiza temelji se na regresijama zarada Mincer tipa i tehnici dekompozicije Blinder-Oaxaca posebno dizajniranoj za takvu analizu.

Neprilagođena rodna razlika u platama procjenjuje se u rasponu od 5% do 8% (zavisno o podacima i metodologiji), što ukazuje na to da žene na tržištu rada u Bosni i Hercegovini zarađuju manje od muškaraca. Analiza zatim ispituje mijenja li se ova relativno skromna razlika nakon kontrole faktora kao što su obrazovanje, dob, prebivalište, bračni status, građanski angažman i sektor zaposlenja. Rezultati pokazuju da većina rodne razlike u platama nije posljedica razlika u karakteristikama poput obrazovanja ili iskustva, već razlika u načinu na koji se te karakteristike nagrađuju na tržištu rada.

Prilagođeni RRP, procijenjen nakon kontrole uočljivih karakteristika i primjene pristupa dekompozicije, dosljedno iznosi oko 13%, što ga čini gotovo dvostruko većim od neprilagođene razlike. To implicira da žene efektivno gube ekvivalent otprilike jednog i pol mjeseca zarade godišnje, što predstavlja značajnu razliku. Ovi nalazi ukazuju na to da su rodne nejednakosti djelomično sakrivene u jednostavnim prosjecima i postaju mnogo izraženije kada se uzmu u obzir uočljive razlike, što sugerira da se neprilagođene mjere trebaju tretirati s oprezom.

Analiza identificira ključne faktore povezane s razlikama u zaradi, uključujući obrazovanje, prebivalište u urbanom području, status ranjivosti i političko učestvovanje. Iako obrazovanje općenito donosi snažne prinose, evidentne su važne rodne asimetrije: žene ostvaruju niže prinose od srednjoškolskog i tercijarnog obrazovanja od muškaraca. Prebivalište u urbanom području povezano je s višim prihodima i čini se da je jedini faktor koji više koristi ženama, iako ta prednost nije dovoljna da nadoknadi ukupnu razliku. Političko učestvovanje povezano je s višim prihodima, ali prvenstveno za muškarce, što sugerira nejednak pristup mrežama s visokim prinosima kroz politiku, što dodatno povećava razliku. Ranjivost također značajno smanjuje prihode, s izraženijim negativnim efektima za žene.

Analiza efekata interakcije pokazuje da rodne nejednakosti ne oblikuju samo individualne karakteristike već i njihov kombinirani utjecaj. Niži prinosi od obrazovanja, ograničen pristup mrežama utjecaja i veća izloženost ranjivosti, kada se javljaju zajedno, stvaraju posebno duboke nepovoljne uslove za određene grupe žena. To naglašava važnost intersekcionalne perspektive i u skladu je sa širim dokazima koji pokazuju da su žene i dalje nedovoljno zastupljene u bolje plaćenim i rastućim sektorima poput zelenih industrija, STEM-a i umjetne inteligencije.

SADRŽAJ

1. UVOD **11**

2. RAZLIČITI DOKAZI O RODNOJ RAZLICI U PLATAMA U BIH **14**

3. RODNI BAROMETAR I EKONOMIJA NJEGE U BIH **16**

4. SAVREMENE RAZLIKE U SEKTORU STEM, ZELENOM SEKTORU I UI **18**

5. PRILAGOĐENA RODNA RAZLIKA U PLATAMA – EMPIRIJSKA ANALIZA **20**

5.1. Izvori podataka 20

5.2 Deskriptivna statistika 22

5.3 Empirijska metodologija 25

5.4 Rezultati i analiza 27

5.4.1. Rodna razlika u platama - Mincerova funkcija zarade 28

5.4.2 Rodna razlika u platama - dekompozicija Blinder-Oaxaca 34

5.5 Efekti interakcije sa roda 36

5.6 Analiza robusnosti 43

6. ZAKLJUČAK **44**

7. IMPLIKACIJE ZA POLITIKE **46**

8. PREDNOSTI, OGRANIČENJA I PRIJEDLOZI ZA BUDUĆA ISTRAŽIVANJA **49**

REFERENCE **51**

DODACI **54**

POPIS TABELA

Tabela 1. Opažene karakteristike iz skupa podataka UNDP-ovog rodnog barometra 24

Tabela 2. Parne korelacije između glavnih Mincerovih varijabli 25

Tabela 3. Rodna razlika u platama procijenjena u funkciji zarade Mincer 29

Tabela 4. Rodna razlika u platama procijenjena u funkciji zarade Mincera u poduzorcima 32

Tabela 5. Sažetak rodna razlika u platama u poduzorcima spolova 32

Tabela 6. Prilagođeni GPG procijenjen Blinder-Oaxaca metodom, modeli 1-6 34

Tabela 7. Bonferronijevi prilagođeni efekti (rod, obrazovanje, političko učestvovanje) 40

Tabela 8. Bonferronijevi prilagođeni efekti (rod, obrazovanje, ranjivost) 41

Tabela 9. Prilagođeni RRP, metoda Blinder-Oaxaca, puna procjena Modela 6 54

POPIS SLIKA

Slika 1. Raspodjela prihoda, ukupni mjesečni neto prihod u 2023., srednje vrijednosti 22

Slika 2. Dvosmjerna interakcija roda i političkog učestvovanja 37

Slika 3. Dvosmjerna interakcija roda i obrazovanja 38

Slika 4. Dvosmjerna interakcija roda i zaposlenosti u javnom sektoru 39

1. UVOD

Rodna razlika u platama (RRP – eng. GPG) definirana je kao oblik strukturne diskriminacije koja proizlazi iz horizontalne i vertikalne segmentacije tržišta rada. Utvrđeno je da je uzrokovana različitim faktorima poput nedovoljne zastupljenosti žena na vodećim pozicijama, različitih obrazaca angažmana radne snage, obrazovanja, vremena izvan posla, feminiziranih poslova, dok dokazi i dalje ukazuju na neobjašnjive dijelove rodne razlike u platama u mnogim skupovima podataka (ILO, 2019.). Rješavanje RRP-a temeljni je stub pravednog društva i odražava temeljnu društvenu vrijednost, jer omogućuje ženama, muškarcima i nebinarnim osobama da ostvare svoj puni potencijal kao ljudska bića (AIRE i UNDP, 2023.). Štoviše, trajna rodna razlika u platama i nepovoljan položaj na tržištu rada mogu dovesti do rodne razlike u bogatstvu, što znači da žene posjeduju manje bogatstva (Waitkus i Minkus, 2021.), te su kao posljedica toga osjetljivije na krize i strukturne kočnice ili šokove s kojima bi se mogle suočiti u budućnosti.

Trajne rodne razlike u platama predstavljaju ključnu prepreku inkluzivnom rastu, socijalnoj koheziji i jednakosti mogućnosti (ILO, 2026.). Stoga je analiza rodne razlike u platama ključna za razumijevanje kako se rezultati na tržištu rada razlikuju između žena i muškaraca te za utvrđivanje proizlaze li uočene razlike iz razlika u karakteristikama ili iz nejednakih prinosa od tih karakteristika (neprilagođena i prilagođena razlika). Bez takve analize, politički odgovori riskiraju da rješavaju simptome, a ne strukturne pokretače nejednakosti.

Rješavanje potencijalne diskriminacije u platama između žena i muškaraca stoga bi trebalo postati i jest ključni prioritet politika rodne ravnopravnosti u većini zemalja (ILO, 2026.). To uključuje Bosnu i Hercegovinu, post-konfliktnu i tranzicijsku zemlju koja teži postati dijelom EU, zemlju koja je 2003. godine usvojila Zakon o rodnoj ravnopravnosti promovirajući jednake mogućnosti za sve građane, sprječavajući direktnu i indirektnu rodnu diskriminaciju. Štoviše, Vijeće ministara BiH je 2024. godine usvojilo Akcijski plan za rodnu ravnopravnost BiH za razdoblje 2023. – 2027. Plan sadrži strateške prioritete i ciljeve za ciljano razdoblje usmjerene na rješavanje rodne razlike u ovom društvu.

Nije lako izmjeriti ili procijeniti bilo koji socioekonomski fenomen, uključujući rodne razlike u platama. Štoviše, mjerenje ili aproksimacija rodne razlike u platama može se osloniti na širok raspon indikatora i izvora podataka, koji također utječu na to kako se rezultati tumače. U praksi se koriste i sekundarni izvori podataka (kao što su administrativni zapisi i ankete o radnoj snazi) i primarni podaci prikupljeni putem namjenskih studija (npr. istraživanje UNDP-ovog Rodnog barometra iz 2024.). Indikatori se mogu temeljiti na bruto ili neto zaradi, s daljim razlikama između redovnih plata i ukupne neto zarade koje uključuju bonuse, dodatke i druge oblike naknade. U nekim kontekstima, procjene prihoda iz neformalne ekonomije uključene su kako bi se pružila tačnija slika stvarnih razlika u platama. Rodna razlika u platama može se izračunati i na satnoj,

sedmičnoj, mjesečnoj ili godišnjoj osnovi, zavisno o dostupnosti podataka i analitičkom fokusu. Zaista, postoje očite razlike između zemalja u njihovom izboru vremena posmatranja (AIRE i UNDP, 2023.). Iako ova raznolikost indikatora omogućuje nijansiranije razumijevanje rodno zasnovane nejednakosti u platama na tržištu rada, potreban je oprez pri poređenju rezultata različitih studija, zemalja ili razdoblja.

Dvije glavne vrste rodnih razlika u platama (RRP) se obično opažaju i koriste kao dokaz potencijalne rodno zasnovane diskriminacije. Prva, šira i jednostavnija za izračun, je neprilagođeni RRP, koji mjeri ukupnu razliku u prosječnoj zaradi između žena i muškaraca. Ovaj indikator odražava ne samo potencijalnu diskriminaciju već i razlike u prosječnim karakteristikama žena i muškaraca koje mogu postojati na tržištu rada. Kao rezultat toga, neprilagođeni RRP ne obuhvaća nužno samo rodnu diskriminaciju i treba ga tumačiti imajući na umu tu napomenu. Stoga, na prvi pogled nikakve ili male rodne razlike u platama mogu zavarati (Gashi i Adnett, 2020.; Braunstein, 2026.) i potencijalna rodna diskriminacija nije vidljiva na prvi pogled, što implicira da su potrebne naprednije metodologije za identifikaciju RRP-a u jednom društvu.

Drugi pristup ide korak dalje pokušavajući prevladati slabosti neprilagođenog RRP-a i procjenjujući zaista prilagođeni RRP. Ovo je metoda koja uzima u obzir razlike u karakteristikama između žena i muškaraca na tržištu rada. Prilagođeni RRP daje procjenu rodne razlike u platama uslovljenu individualnim karakteristikama, uključujući posmatrane, a u nekim metodologijama i neposmatrane faktore. Konvencionalne metode procjene koje se mogu tretirati kao prilagođene metodologije uključuju procjenu funkcija zarade, kao što je Mincerova jednadžba (Mincer, 1974.), koja omogućuje procjenu rodne razlike u platama uslovljenu posmatranim karakteristikama uključenim u model zarade (npr. dob, iskustvo, obrazovanje i sektor). Osim toga, metoda dekompozicije Blinder-Oaxaca posebno je korisna i preporučuje je Eurostat za razlikovanje objašnjenih i neobjašnjenih komponenti razlike u platama između žena i muškaraca (Leythienne i Ronkowski, 2018.). Ovaj pristup procjenjuje rodnu razliku u platama prema scenariju koji nije stvarni, a u kojem muškarci i žene imaju identične posmatrane karakteristike (Ronald Oaxaca, 1973.), pri čemu neobjašnjena komponenta obuhvaća prilagođenu razliku. Ova studija će primijeniti obje metodologije na primarne podatke prikupljene u Bosni i Hercegovini s ciljem dobivanja uvida u bezuslovne i uslovne rodne razlike u platama, kao i u razlike među njima ako postoje.

Rigorozna procjena uslovne rodne razlike u platama pruža dokaze o tome u kojoj mjeri tržišta rada različito nagrađuju obrazovanje, iskustvo i učestvovanje na tržištu rada prema rodu. Ova je razlika posebno važna za oblikovanje politika, budući da intervencije usmjerene isključivo na poboljšanje ljudskog kapitala žena mogu imati ograničen utjecaj ako su razlike uzrokovane praksama određivanja plata, profesionalnom segregacijom ili institucionalnim ograničenjima, što se može sistematski posmatrati u rodno prilagođenim modelima. Empirijska (ekonometrijska) analiza stoga je ključna za informiranje trebaju li napori politike dati prioritet razvoju vještina, regulaciji tržišta rada, mehanizmima provedbe ili širim sistemskim reformama usmjerenim na osiguranje jednakog tretmana. Takva je analiza posebno važna u post-konfliktnim i tranzicijskim okruženjima, kao što je Bosna i Hercegovina, gdje su dokumentirani dokazi o potencijalnoj rodno zasnovanoj diskriminaciji u ishodima na tržištu rada (npr. Efendić i Pugh, 2018.; Rizvanović i Efendić, 2021.; Shehaj , 2022.; Kovačević i Rizvić, 2022.; UNDP i Agencija za ravnopravnost spolova, 2024 .; Efendić, 2025.; ASBIH, 2025.).

Proučavanje rodne razlike u platama također je ključno za praćenje napretka prema državnim i međunarodnim obavezama o rodnoj ravnopravnosti, dostojanstvenom radu i inkluzivnom razvoju u svim područjima (WEF, 2025.; ILO, 2026.). Na primjer, nedavni izvještaj UNDP-a o ljudskom razvoju (2025.) naglasio je nove mogućnosti u doba umjetne inteligencije (UI). Iako je u posljednjih nekoliko decenija postignut značajan napredak, izvještaji zaključuju da i dalje postoje značajne rodne razlike u digitalnim vještinama, pristupu obrazovanju STEM (nauka, tehnologija, inženjerstvo i matematika) i učestvovanju u tehnološkoj radnoj snazi. Međutim, rodne nejednakosti u dizajnu i korištenju UI nisu odraz nižih tehnoloških kapaciteta, interesa ili vještina žena. Umjesto toga, proizlaze iz diskriminirajućih društvenih normi (UNDP HDR, 2025.), što implicira potrebu za pažljivim posmatranjem i politikama.

Rodna nejednakost ima direktne implikacije na ekonomsku sigurnost žena, doživotni prihod, adekvatnost penzija i rizik od siromaštva, kao i na širu dobrobit domaćinstva i međugeneracijske ishode, uključujući nejednakost bogatstva žena (Waitkus i Minkus, 2021.). Iz perspektive upravljanja, transparentno mjerenje razlika u platama jača odgovornost i podržava donošenje politika temeljenih na dokazima. Tako je ovaj izvještaj izrađen korištenjem pristupa Equanomics, holističke metodologije primijenjene u saradnji između UNDP-a u Bosni i Herzegovini, Agencije za ravnopravnost spolova Bosne i Hercegovine pri Ministarstvu za ljudska prava i izbjeglice BiH te Foruma žena za razvoj (Women's Forum for Development – WF4D). Equanomics se zalaže za okvir osjetljiv na kontekst i usmjeren na politiku koji integrira konvencionalnu ekonomsku analizu s rodno osjetljivim perspektivama, uzimajući u obzir dinamiku tržišta rada specifičnu za zemlju, institucionalne strukture i društvene norme koje utječu na rodne nejednakosti. Odražavajući to, studija koristi Eurostatov prilagođeni model rodne razlike u platama kao svoju osnovu (Leythienne i Ronkowski, 2018.), osiguravajući tako usklađenost sa standardima EU i obogaćujući analizu primarnim podacima iz Rodnog barometra u Bosni i Herzegovini (2024.). Integracijom pristupa Equanomics, studija postiže metodološku strogost i lokalnu relevantnost, efektivno povezujući najbolje međunarodne prakse s kontekstualno specifičnim uvidima kako bi se unaprijedila rodno osjetljiva ekonomska politika.

Konačno, studija je strukturirana na sljedeći način. Nakon ovog uvoda, sljedeći odjeljak pregledava različite dokaze o rodnoj razlici u platama u Bosni i Hercegovini, nakon čega studija predstavlja skup podataka Rodnog barometra i raspravlja o njegovoj relevantnosti u kontekstu ekonomije njege. Zatim se studija bavi rodnim razlikama u sektorima s visokim rastom kao što su STEM, zelene industrije i umjetna inteligencija. Sljedeći empirijski odjeljak opisuje izvore podataka i metodološki pristup korišten za procjenu rodne razlike u platama, s posebnim naglaskom na prilagođene modele i ekonometrijske tehnike. Nakon toga slijedi prikaz empirijskih rezultata i njihova detaljna analiza, uključujući namjensko ispitivanje efekata interakcije s rodnim provjerama i provjerama robusnosti. Završni odjeljci raspravljaju o glavnim nalazima, implikacijama na politike te snagama, ograničenjima i smjerovima studije za buduća istraživanja. Literatura i Dodatak nalaze se na kraju izvještaja.

2. RAZLIČITI DOKAZI O RODNOJ RAZLICI U PLATAMA U BIH

Postoji nekoliko studija i statističkih izvora koji pružaju dokaze o rodnoj razlici u platama u Bosni i Hercegovini. Njihove procjene nisu uvijek direktno usporedive zbog razlika u izvorima podataka, metodama procjene i razdobljima posmatranja, ipak, one pokazuju znatne varijacije u prijavljenoj veličini razlike. Usprkos toj varijaciji, dokazi dosljedno potvrđuju postojanje rodne razlike u platama, bez nalaza koji sugeriraju da je nema ili da ide u korist muškarcima. Istovremeno, obrasci uočeni u različitim studijama ukazuju na to da se razlika s vremenom može postepeno smanjivati, pri čemu neke procjene izvještavaju o relativno niskim nivoima RRP-a, posebno ako se posmatraju neprilagođeni nedavni podaci. Iako takve „zvučne brojke“ s nekoliko postotaka razlike mogu biti ohrabrujuće, glavni izazov je zaista pravilno razumijevanje koji se podaci posmatraju i kako ih treba tumačiti (Braunstein, 2026). Ipak, trajna ukupna razlika u platama koja žene stavlja u nepovoljan položaj i dalje je uobičajeni zaključak u literaturi usmjerenoj na Bosnu i Hercegovinu, ukazujući na kontinuirane rodno zasnovane nejednakosti na tržištu rada ove zemlje. Neke od takvih glavnih studija i izvještaji raspravljaju se u nastavku.

Započinjemo s dvije povezane publikacije objavljene u okviru Vijeća za regionalnu saradnju (RCC), koje ispituju rodne razlike u platama iz regionalne i specifične perspektive za pojedinu zemlju. U komparativnoj analizi, Shehaj (2022.) istražuje neprilagođene rodne razlike u platama u različitim zanimanjima i sektorima koristeći podatke o bruto mjesečnim platama za 2020. godinu. Studija otkriva da rodne razlike u platama i dalje postoje u svim ekonomijama Zapadnog Balkana, s prosječnom razlikom od 17,3%. Analiza također identificira značajne rodne razlike u zapošljavanju, a posebno među starijim ženama s nižim stepenom obrazovanja, usprkos tome što su žene u prosjeku obrazovanije od muškaraca. U sklopu istog projekta, Kovačević i Kapo (2022.) posebno se fokusiraju na Bosnu i Hercegovinu, ispitujući razlike u zanimanjima u razdoblju 2016. – 2020. Njihovi nalazi potvrđuju značajnu ukupnu razliku od oko 38%, posebno izraženu u zanimanjima u kojima dominiraju muškarci, kao što su oružane snage, rukovanje postrojenjima i mašinama te obrtništvo. Nasuprot tome, žene zarađuju nešto više u uslužnom sektoru, prodaji i nekim profesionalnim i administrativnim zanimanjima. Ipak, rodna razlika u platama i dalje je značajna na menadžerskim pozicijama, što odražava vertikalnu segregaciju zanimanja. Budući da se ove procjene temelje na neprilagođenim podacima, veličina razlike može se razlikovati nakon što se uzmu u obzir individualne karakteristike i karakteristike povezane s poslom.

Za razliku od prethodnih studija, Agencija za statistiku Bosne i Hercegovine (2024.) izvještava o relativno niskoj neprilagođenoj rodnoj razlici u platama od 3,6%, na temelju Istraživanja o strukturi zarada iz 2022. Muškarci su u prosjeku zarađivali 12,0 KM po satu u poređenju s 11,6 KM za žene, dok je godišnja zarada iznosila 24.579 KM za muškarce i 23.485 KM za žene. Iako ove brojke sugeriraju skromnu razliku na agregatnom nivou, one prikrivaju značajne razlike među sektorima, zanimanjima i nivoima obrazovanja. Strukturni faktori, poput profesionalne segregacije, sektorske distribucije i niskog učestvovanja ženske radne snage, igraju važnu ulogu. Zaista, zaposlenost žena u Bosni i Hercegovini i dalje je znatno niža od zaposlenosti muškaraca (55% za muškarce naspram 32% za žene u 2024.; ASBIH, 2026.), što može utjecati na uočenu razliku. Štoviše, budući da se podaci temelje na zaradama koje su prijavile kompanije, mogu biti prisutne i potencijalne pristranosti u izvještavanju. Kao što tvrde Gashi i Adnett (2020.), zemlje s niskim učestvovanjem ženske radne snage obično pokazuju relativno niske neprilagođene razlike u platama zbog efekata selekcije. Jednostavno rečeno, žene s većim potencijalom zarade imaju veću vjerojatnost učestvovanja na tržištu rada. Kao posljedica toga, neprilagođene mjere mogu podcijeniti stvarne rodne razlike. Slične zabrinutosti izražavaju Redmond i McGuinness (2017.), koji pokazuju da su se, iako su se neprilagođene razlike u Europi smanjile, prilagođene razlike često povećale.

Posebno prikupljeni rodno zasnovani indikatori su prikazani u UNDP-ovom Rodnom barometru (2024.), koji koristi reprezentativne podatke ankete prikupljene u Bosni i Hercegovini. Na temelju transformiranih kategorija prihoda i slijedeći metodologiju Eurostata (pogledajte empirijske odjeljke za više detalja o ovim izračunima), procijenjena neprilagođena rodna razlika u platama iznosi približno 8%, što ukazuje na to da žene u prosjeku zarađuju manje od muškaraca. Budući da je ova procjena također neprilagođena, ona odražava agregatne razlike bez uzimanja u obzir varijacija u individualnim ili s poslom povezanim karakteristikama. Slično tome, naša procjena u empirijskim odjeljcima koja se temelji na podacima iz Istraživanja javnog mnijenja RCC-a Balkanski Barometar (2025.) pokazuje da je neprilagođena rodna razlika u platama oko 9%, slično prethodnom nalazu.

Rodne razlike protežu se izvan formalnog tržišta rada na neformalne i neprijavljene ekonomske aktivnosti. Dokazi iz studije Efendića (2025.) za Zapadni Balkan pokazuju da su muškarci skloniji neformalnom zaposlenju i ostvaruju veći dodatni prihod od takvih aktivnosti, dok su žene nedovoljno zastupljene među onima s višim primanjima i koncentrirane su u kategorijama s nižim prihodima. Ovi nalazi sugeriraju da rodno zasnovane nejednakosti u prihodima postoje i u formalnom i u neformalnom sektoru. Međutim, postojeći dokazi ne kvantificiraju prilagođene ili neprilagođene rodne razlike u platama u smislu razlika u prihodima, već se fokusiraju na vjerojatnost učestvovanja u svim kategorijama prihoda, što ukazuje na važno područje za buduća istraživanja.

Sveukupno, dostupne studije pokazuju da procjene rodne razlike u platama nisu direktno usporedive zbog razlika u skupovima podataka, pristupima mjerenju i metodama procjene, pri čemu se većina oslanja na neprilagođene indikatore. Ipak, dostupni dokazi dosljedno ukazuju na značajnu rodnu razliku u platama koja se s vremenom možda donekle smanjila, u skladu s globalnim trendovima (WEF, 2025.). Međutim, ove nalaze treba tumačiti s oprezom, ističući važnost analiza temeljenih na prilagođenim podacima i naprednijim ekonometrijskim tehnikama, što je cilj kojim se ova studija želi pozabaviti.

3. RODNI BAROMETAR I EKONOMIJA NJEGE U BIH

Kako bi se obogatila analiza rodne razlike u platama, ova studija stavlja poseban naglasak na Barometar rodne ravnopravnosti Bosne i Hercegovine (BRR BiH – eng. GEB BiH), objavljen 2024. godine. Barometar pruža bitan kontekst u vezi s društvenim normama, stavovima i strukturnim preprekama koje oblikuju ishode ženskog tržišta rada. Ovo pruža analitički potencijal iz perspektive ekonomije njege, jer pruža reprezentativne i detaljne dokaze o korištenju vremena, praksama njege i podjeli rada unutar domaćinstva u BiH. BRR su zajednički proveli UNDP i Agencija za ravnopravnost spolova BiH i on koristi dizajn sa mješovitim metodama, kombinirajući reprezentativno istraživanje 1800 ispitanika s kvalitativnim fokus grupama. Ovaj pristup daje i statističke i iskustvene uvide u rodne odnose. Kvantitativni dio ovog izvještaja direktno se oslanja na podatke BRR BiH (2024), pružajući tako komplementarnu analitičku studiju koja obuhvaća kvantitativne empirijske dimenzije koje prije nisu istražene.

Nalazi Barometra rodne ravnopravnosti u Bosni i Hercegovini (BRR BiH) otkrivaju značajnu razliku između deklarativne podrške rodnoj ravnopravnosti i stvarnosti. Iako velika većina ispitanika vjeruje da se rodna ravnopravnost poboljšala i da je formalno garantirana zakonom, ta percepcija koegzistira s trajnim strukturnim nejednakostima koje i dalje oblikuju ekonomsko učestvovanje i zaradu žena. Ova nepovezanost posebno je relevantna za analizu rodne razlike u platama, jer sugerira da sami pravni okviri nisu dovoljni za rješavanje duboko ukorijenjenih razlika u rezultatima na tržištu rada.

Centralni nalaz iz BRR-a BiH odnosi se na nejednaku raspodjelu neplaćene njege i kućanskih obaveza, koja ostaje snažno rodno uslovljena usprkos određenom napretku tokom vremena (UNDP i Agencija za ravnopravnost spolova BiH, 2024.). Žene i dalje snose primarnu odgovornost za kućanske poslove i zadatke njege, što ograničava njihovo raspoloživo vrijeme, učestvovanje na tržištu rada i napredovanje u karijeri. Ta su ograničenja direktno povezana s rodnim razlikama u platama, jer ograničavaju pristup žena zaposlenju s punim radnim vremenom, bolje plaćenim zanimanjima i vodećim pozicijama (Braunstein, 2026.). U kontekstu sektora u nastajanju poput zelene ekonomije, gdje su radna mjesta često koncentrirana u zahtjevnijim, tehničkim i manje fleksibilnim zanimanjima, ove strukturne barijere mogu dodatno ograničiti sposobnost žena da iskoriste nove mogućnosti na tržištu rada (UNDP HDR, 2025.).

BRR BiH (2024) dodatno ističe trajne nejednakosti u praksama tržišta rada, uključujući diskriminaciju pri zapošljavanju i napredovanju. Žene tako prijavljuju suočavanje s preprekama povezanim s trudnoćom i planiranjem porodice, a poslodavci često nerado zapošljavaju ili zadržavaju žene u reproduktivnoj dobi. Takve prakse pojačavaju profesionalnu segregaciju i doprinose prekidima u karijernim putanjama žena, s dugoročnim implikacijama na zaradu. Ovi nalazi u skladu su s širim dokazima o zelenim radnim mjestima i zapošljavanju vezanom uz STEM, gdje ograničeno učestvovanje žena u tehničkim područjima i vodećim ulogama ograničava njihov pristup bolje plaćenim segmentima tržišta rada (WEF, 2025.; ILO, 2026.).

Osim toga, izvještaj ukazuje na kontinuiranu nedovoljnu zastupljenost žena u donošenju odluka i javnom životu, što odražava šire neravnoteže moći koje se protežu i na ekonomske strukture. Već je utvrđeno da muškarci ulažu više vremena i novca u umrežavanje u cijeloj regiji zapadnog Balkana, uključujući političko umrežavanje, što je mehanizam podrške koji im omogućuje pristup mrežama s visokim povratom i isplativosti s većim prihodima u formalnom i neformalnom sektoru ekonomije (Efendić i Ledeneva, 2020.; Efendić, 2025.). Ograničena prisutnost žena na vodećim pozicijama, kako u politici tako i na radnom mjestu, utječe ne samo na njihove individualne izglede za zaradu, već i na stepen u kojem se rodno osjetljive politike na kraju oblikuju i provode.

Uzeti zajedno, nalazi Rodnog barometra naglašavaju da su rodne razlike u platama u BiH duboko ukorijenjene u strukturnim i sociokulturnim faktorima, uključujući rodne norme, podjelu rada i nejednak pristup prilikama (UNDP i Agencija za ravnopravnost spolova BiH, 2024.). Ti faktori međusobno djeluju s tekućim ekonomskim transformacijama, a posebno širenjem zelenih sektora i sektora STEM-a, kako bi utjecali na to ko ima koristi od novonastalih, bolje plaćenih poslova.

Uz ograničenja povezana sa njegom, nalazi ukazuju na važnost uslova na radnom mjestu i institucionalnih okvira kao faktora koji omogućuju učestvovanje i zaradu žena na tržištu rada. Politike koje podržavaju ravnotežu između poslovnog i privatnog života, poput onih koje se odražavaju u Direktivi EU o ravnoteži između poslovnog i privatnog života (Europska unija, 2019.), igraju ključnu ulogu u smanjenju strukturnih prepreka promocijom fleksibilnih radnih aranžmana, roditeljskog dopusta i pravednije podjele odgovornosti za njegu. Istovremeno, rješavanje rizika na radnom mjestu poput seksualnog uznemiravanja i zlostavljanja ključno je za osiguranje ne samo zapošljavanja žena, već i njihovog zadržavanja i napredovanja u karijeri, kako je istaknuto u međunarodnim radnim standardima o nasilju i uznemiravanju na radu (ILO, 2019.) . Iako su empirijski dokazi o direktnom utjecaju ovih mjera na rodne razlike u platama i dalje ograničeni, širi dokazi upućuju na to da uslovi na radnom mjestu i institucionalna podrška značajno oblikuju rezultate rodne ravnopravnosti na tržištima rada (OECD, 2023.). Ova perspektiva usko je usklađena s pristupom Equanomics i Pečatom rodne ravnopravnosti, koji naglašavaju ulogu politika na radnom mjestu i organizacijskih standarda kao transformacijskih alata za unapređenje rodne ravnopravnosti. Jačanje ovih dimenzija uz intervencije u ekonomiji njege stoga je ključno za rješavanje strukturnih pokretača rodne razlike u platama u Bosni i Hercegovini.

4. SAVREMENE RAZLIKE U SEKTORU STEM, ZELENOM SEKTORU I UI

Ovaj odjeljak nadopunjuje ukupnu analizu rodne razlike u platama ispitivanjem kako tekuća zelena tranzicija mijenja rezultate tržišta rada za žene i muškarce. Štoviše, povezujemo je s učestvovanjem žena u sektorima ekonomije STEM i UI. Skup podataka koji koristimo ne kodira te sektore, što našu empirijsku analizu za ta područja čini ograničenom, a što prevladavamo pozivanjem na postojeće UNDP-ove studije s ovim fokusom, a posebno na izvještaje UNDP-a i OECD-a (2025.) te UNDP-ovog HDR-a (2025.).

Izvještaj UNDP-a i OECD-a (2025.) usmjeren je na pitanje „Kako Europa i Srednja Azija mogu postići rodnu ravnopravnost kroz zelenu tranziciju?“, s posebnim osvrtom na ulogu STEM-a i zelenih radnih mjesta. Iako Bosna i Hercegovina nije direktno obuhvaćena kvantitativnom komponentom regionalne analize u izvještaju, nalazi iz Europe i Srednje Azije pružaju vrlo relevantne uvide s obzirom na slične strukturne karakteristike tržišta rada, uključujući segregaciju zanimanja, neusklađenost vještina i rodno uslovljene obrasce zapošljavanja.

Nalazi pokazuju da zeleni poslovi trenutno predstavljaju mali, ali rastući segment ukupne zaposlenosti (oko 3%), no već su povezani s važnim implikacijama za strukturu plata i rodnu ravnopravnost. U analiziranim europskim zemljama zelene poslove pretežno drže muškarci, dok žene zauzimaju otprilike trećinu tih pozicija. Ovaj nejednak pristup posebno je značajan u kontekstu rodne razlike u platama, budući da zeleni sektori imaju tendenciju biti dinamičniji, produktivniji i često bolje plaćeni od tradicionalnih sektora. Kao rezultat toga, nedovoljna zastupljenost žena u zelenim poslovima donosi rizik pojačavanja postojećih nejednakosti u prihodima. UNDP HDR (2025.) također zaključuje da, iako su zeleni sektori često povezani s većom produktivnošću i potencijalom plata, ograničeno i neravnomjerno učestvovanje žena znači da te koristi nisu jednako raspoređene, što bi u budućnosti moglo proširiti postojeću rodnu razliku u platama.

Ključni pokretač novonastalih rodnih razlika u platama leži u segregaciji zanimanja unutar zelene ekonomije. Žene su vjerojatnije koncentrirane u užem rasponu zanimanja, koja često zahtijevaju viši nivo obrazovanja, ali nude manje mogućnosti zapošljavanja. Nasuprot tome, muškarci su šire raspoređeni u srednje i visokokvalificiranim zelenim zanimanjima, uključujući tehničke i industrijske uloge koje su ključne za širenje zelenih sektora poput energetike, građevinarstva i infrastrukture. Ta zanimanja nisu samo brojnija, već su često povezana i s većim rastom plata, čime se povećava ukupna razlika u zaradama (UNDP HDR, 2025.).

Strukturne barijere dodatno oblikuju te nejednakosti. Analiza ističe trajna ograničenja povezana s nejednakim pristupom obrazovanju STEM i osposobljavanju, ograničenim učestvovanjem u tehničkim područjima, obavezama njege i ograničenim pristupom mogućnostima napredovanja u karijeri. Ti faktori ograničavaju ulazak žena u zelene sektore i napredovanje unutar njih, što direktno utječe na zaradu. U Bosni i Hercegovini, gdje se uočavaju slični izazovi, uključujući niže učestvovanje ženske radne snage, snažne rodne norme i neravnomjeran pristup njezi za djecu i osposobljavanju (UNDP i Agencija za ravnopravnost spolova, 2024.), ove će barijere vjerojatno igrati jednako značajnu ulogu u oblikovanju rodnih razlika u platama u novim zelenim industrijama. Sveukupno, nalazi sugeriraju da bi, bez ciljanih i rodno osjetljivih mjera politike, zelena tranzicija mogla replicirati ili čak pogoršati postojeće rodne razlike u platama (UNDP HDR, 2025.). Za Bosnu i Hercegovinu to naglašava važnost sistematskih integriranja rodnih pitanja u politike zelene tranzicije.

Izvještaj o ljudskom razvoju za 2025. ističe trajne rodne razlike u korištenju i koristima od umjetne inteligencije, što odražava šire strukturne nejednakosti u digitalnom pristupu, vještinama i učestvovanju na tržištu rada (UNDP HDR, 2025.). Žene su i dalje nedovoljno zastupljene u obrazovanju STEM i područjima povezanim s umjetnom inteligencijom, s obzirom na to da samo oko trećine diplomanata u nauci, tehnologiji, inženjerstvu i matematici čine žene, mada se taj obrazac s vremenom malo promijenio. Ova obrazovna razlika prevodi se u nejednako učestvovanje u sektoru umjetne inteligencije i ograničava pristup žena novim, bolje plaćenim tehnološki orijentiranim zanimanjima.

Osim toga, izvještaj otkriva da muškarci češće od žena koriste alate umjetne inteligencije za posao, bez obzira na nivo obrazovanja, što ukazuje na rodno uslovljenu digitalnu razliku u primjeni novih tehnologija. Ove razlike dodatno su pojačane strukturnim faktorima, uključujući neproporcionalne odgovornosti žena u njezi i šire nejednakosti na tržištu rada, što ograničava njihovu sposobnost stjecanja digitalnih vještina i angažmana u ulogama koje intenzivno koriste umjetnu inteligenciju. Kao rezultat toga, bez ciljanih intervencija, širenje umjetne inteligencije donosi rizik pojačavanja postojećih rodnih razlika u zaposlenosti, produktivnosti i zaradi, umjesto da ih smanji.

5. PRILAGOĐENA RODNA RAZLIKA U PLATAMA – EMPIRIJSKA ANALIZA

Ovaj odjeljak predstavlja podatke i empirijsku strategiju korištenu za analizu rodne razlike u platama unutar prilagođenih metoda procjene. Opisuje izvore podataka i ključne varijable, ocrtava transformaciju varijabli i specifikaciju modela te detaljno opisuje korištene metode procjene. Odjeljak nadalje izvještava o deskriptivnoj statistici i predstavlja glavne empirijske rezultate, uključujući efekte interakcije s rodnim analizama i analizama robusnosti.

5.1. Izvori podataka

Empirijska analiza temelji se na primarnim izvorima podataka prikupljenim u Bosni i Hercegovini tokom posljednjih nekoliko godina. Osnovna empirijska analiza oslanja se na prilagođene podatke prikupljene za projekt Barometar rodne ravnopravnosti koji finansira UNDP, uz analitičku publikaciju čiji su autori Šiljak Spahić i Đipa (2024.). Primarni podaci prikupljeni su 2023. godine korištenjem metode CATI (računarski potpomognuto telefonsko intervjuiranje). Istraživanje je provedeno na slučajnom, reprezentativnom uzorku od 1800 građana na nivou države (900 žena i 900 muškaraca) u dobi od 18 i više godina širom Bosne i Hercegovine (BIH). Detaljan opis metodologije prikupljanja podataka nalazi se u Prilogu I. ovog izvještaja.

Drugi primarni izvor podataka koji će se konsultirati radi provjere dosljednosti ishoda i robusnosti jest istraživanje javnog mnijenja Vijeća za regionalnu saradnju (RCC) Balkanski Barometar provedeno 2025. godine, što su najnoviji podaci koji su se mogli dobiti u vrijeme pisanja studije (početak 2026.). Riječ je o reprezentativnom istraživanju koje da je presjek provedenom u prvoj polovici 2025. u šest ekonomija Zapadnog Balkana, uključujući Bosnu i Hercegovinu (BIH). Istraživanje je provela profesionalna istraživačka agencija, a provedeno je istovremeno u svim ekonomijama učesnicama, čime se osigurala metodološka dosljednost i usporedivost među

zemljama. Konačni regionalni uzorak sastoji se od približno 1000 pojedinaca po ekonomiji, stratificiranih prema ključnim sociodemografskim karakteristikama kako bi se osigurala državna reprezentativnost. U nastavku teksta ovaj skup podataka nazivat će se RCC (2025).

Iako su podaci UNDP-ovog Rodnog barometra (RB) posebno dizajnirani za obuhvaćanje rodno povezanih karakteristika u Bosni i Hercegovini, ključna karakteristika varijable prihoda jest da se mjeri kao kategorička varijabla na temelju raspona prihoda. Ovo je uobičajen izbor u prikupljanju primarnih podataka, jer ispitanici često nerado otkrivaju svoj tačan prihod, što bi moglo dovesti do značajnog gubitka uzorka, dok su općenito spremniji prijaviti prihod unutar unaprijed definiranih raspona. Uobičajeni metodološki pristup u takvim slučajevima je normalizacija ovih kategorija u transformiranu varijablu dodjeljivanjem srednje vrijednosti svakog intervala prihoda, a potom transformacijom varijable u logaritamski oblik u sljedećoj fazi. Ova transformacija omogućuje smislenije tumačenje rezultata i poboljšava statistička svojstva modela.

Uz prihod kao ključnu zavisnu varijablu, skup podataka UNDP RB (2024) uključuje nekoliko relevantnih varijabli koje objašnjavaju i obuhvaćaju standardne demografske karakteristike poput dobi, roda, obrazovanja i područja prebivališta, kao i ekonomske karakteristike, uključujući sektor ekonomije i individualnu ekonomsku aktivnost. Međutim, nekoliko potencijalno važnih varijabli nije prikupljeno, poput vrste ugovora o radu, radnog vremena i karakteristika na nivou kompanije, koje bismo rado koristili. Iako bi ovi faktori mogli biti vrijedni za uključivanje u analizu, ovo ograničenje je egzogeno u odnosu na skup podataka i stoga se ne može obraditi u okviru ove studije. Istraživanje također ne obuhvaća određene nove teme, poput zelene ekonomije i učestvovanja u sektoru STEM, kojih smo se dotaknuli u prethodnim odjeljcima pozivajući se na ključne izvještaje UNDP-a s ovim fokusom.

Skup podataka RCC (2025) ima prednost što je noviji, međutim, podložan je i određenim ograničenjima. Pod-uzorak Bosne i Hercegovine uključuje manji broj žena (oko 400) i, slično Rodnom barometru, indikator ličnog prihoda mjeri se kategorički pomoću raspona prihoda. Osim toga, većina prethodno spomenutih karakteristika povezanih sa zaposlenjem nije dostupna. Iz tog razloga, skup podataka RCC služi kao sekundarni izvor i prvenstveno će se koristiti za testiranje robusnosti i dosljednosti rezultata korištenjem novijih podataka.

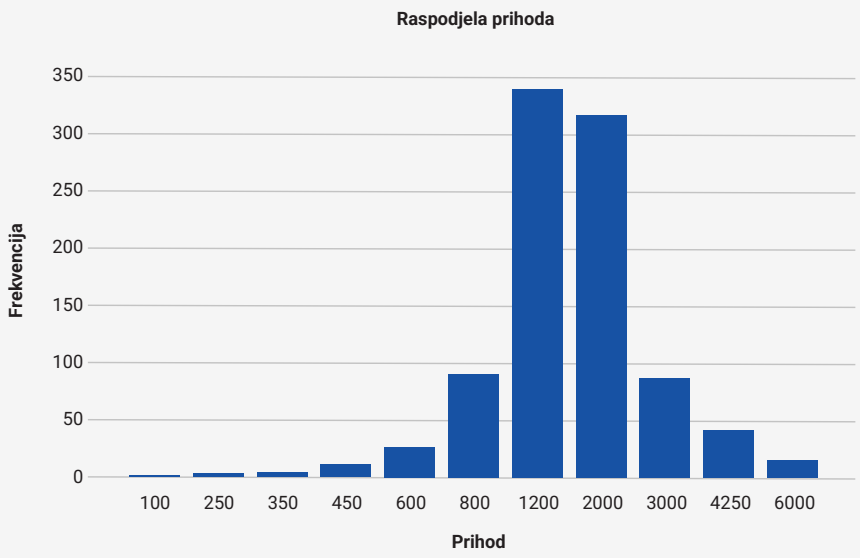
Konačno, preporučeni izvor podataka za buduću analizu mogao bi biti i Istraživanja o strukturi zarada (ISZ – eng. SES), prvi put provedena u Bosni i Hercegovini 2022. godine i usklađena s metodologijom Eurostata koja se primjenjuje u zemljama EU (Leythienne i Ronkowski, 2018.). Ovi podaci pružaju preciznije mjere prihoda (bruto zarade), kao i detaljne karakteristike posla, kao što su radno iskustvo, vrsta zanimanja, vrsta ugovora i karakteristike poduzeća, prikupljene direktno od poduzeća s 10 ili više zaposlenika. Međutim, ovi podaci nisu bili dostupni za empirijska istraživanja u vrijeme pisanja ovog izvještaja. Novi krug prikupljanja podataka planiran je u tekućoj 2026. godini, budući da je skup podataka iz 2022. već najstariji među potencijalnim izvorima. Nakon što budu dostupni, ovi podaci predstavljali bi vrlo vrijedan izvor za sveobuhvatnu analizu rodne razlike u platama, kako u smislu vremenskog okvira, tako i u smislu mogućnosti istraživanja strukturnih pokretača rodne razlike u platama u Bosni i Hercegovini koji su usklađeni s predloženom metodologijom Eurostata.

5.2 **Deskriptivna statistika**

Glavna varijabla koja se koristi za procjenu individualnih prihoda u Bosni i Hercegovini unutar skupa podataka UNDP-ovog Rodnog barometra je kategorička mjera prosječnog neto mjesečnog prihoda. Varijabla ne razlikuje formalni i neformalni prihod, niti redovne i dodatne izvore prihoda. Prednost ove mjere je u tome što obuhvaća ukupan iznos koji pojedinci prijavljuju da primaju „na ruke“ mjesečno, stoga je to ukupni raspoloživi prihod. Međutim, ovo ne omogućuje detaljniju analizu strukture i sastava prihoda.

Prihod se prikazuje u 12 kategorija, od nikakvih prihoda do mjesečnih prihoda većih od 6.000 KM (oko 3.000 eura[1]). Raspodjela prihoda po tim kategorijama prikazana je na Slici 1, gdje su prikazane srednje vrijednosti svake kategorije.

Slika 1. Raspodjela prihoda, ukupni mjesečni neto prihod u 2023., srednje vrijednosti



Izvor: UNDP-ov rodni barometar, 2024.

Raspodjela prihoda prikazana na Slici 1 pokazuje približno zvonasti uzorak, s najvećom koncentracijom opažanja u kategorijama srednjeg prihoda, a posebno u rasponu od otprilike 1200 do 2000 KM. Na donjem kraju, samo mali broj ispitanika prijavljuje izuzetno niske ili nikakve prihode, što sugerira da se uzorak uglavnom sastoji od pojedinaca s barem nekim redovnim prihodima. Na gornjem kraju, raspodjela postaje primjetno tanja iznad otprilike 3000 KM, s tek malim udjelom ispitanika koji prijavljuju vrlo visoke mjesečne prihode (iznad 4000 do 5000 KM), što ukazuje na to

1 Bosanska valuta je vezana uz euro po kursu od 1,95 BAM za 1,0 euro.

da su osobe s visokim prihodima relativno rijetke u uzorku, što se i očekivalo.

Sveukupno, distribucija je samo blago nagnuta udesno i ne pokazuje jaku polarizaciju ili grupiranje na bilo kojem kraju. To je vrijedno pažnje jer podaci o prihodu, posebno kada su uključeni neformalni prihodi, često pokazuju izraženu asimetriju. Relativno gladak, gotovo normalan oblik sugerira da kategorička mjera prihoda, nakon normalizacije korištenjem prosjeka kategorija, pruža razumnu aproksimaciju temeljne distribucije prihoda unutar ispitane populacije.

Ukupni prosječni neto mjesečni prihod u uzorku iznosi 1.718 KM. Kada se rodno razvrsta, prosječna mjesečna zarada za muškarce iznosi 1.777 KM, u poređenju s 1.636 KM za žene. To za rezultat ima apsolutnu rodnu razliku u platama od 141 KM mjesečno, što je ekvivalentno približno 1.692 KM godišnje. U praksi, ova godišnja razlika odgovara gotovo jednoj prosječnoj mjesečnoj plati, što predstavlja značajnu kumulativnu prednost u prihodu za muškarce. Kao što je ranije navedeno, u relativnom smislu, neprilagođena rodna razlika u platama, ako se izračuna prema predloženoj metodologiji Eurostata (Leythienne i Ronkowski, 2018.), iznosi približno 8%.

Kako bi se omogućila kvantitativna analiza prilagođene rodne razlike u platama i primjena relevantnih ekonometrijskih metodologija, kategorička varijabla prihoda normalizirana je dodjeljivanjem srednjih vrijednosti svakoj kategoriji prihoda, kako je ranije objašnjeno. Zatim se lična varijabla prihoda transformira u logaritamski oblik kako bi se omogućila njezina upotreba u funkcijama zarade i naknadnim metodama procjene, što je standardna praksa u empirijskim istraživanjima (Mincer, 1974.). Štoviše, ova transformacija omogućuje tumačenje koeficijenata kao što su elastičnost (tj. postotnih promjena), koji su općenito intuitivniji i lakši za tumačenje od apsolutnih jedinica.

Deskriptivna statistika ključnih varijabli korištenih u empirijskoj analizi utemeljena je na teoriji ljudskog kapitala i, tačnije, na modelima ekonomije rada za određivanje plata, a najznačajniji je Mincerov model (1974.). Mincerov okvir često se primjenjuje u studijama nejednakosti plata i rodne razlike u platama, jer omogućuje istraživačima da procijene kako uočljive karakteristike doprinose razlikama u zaradi.

Uz standardne varijable Mincerovog tipa, analiza također uključuje proširenja ovog okvira koja uključuju karakteristike i specifične karakteristike pojedinaca i tržišta rada u Bosni i Hercegovini koje se mogu kontrolirati unutar skupa podataka. Slijedom toga, empirijska specifikacija uključuje indikatore na više nivoa koji pokrivaju ne samo individualne karakteristike već i kontrole višeg nivoa relevantne za analizu, kao što su geografske regije i aspekti institucionalnog okruženja (npr. efekti entiteta).

Tabela 1. Opažene karakteristike iz skupa podataka UNDP-ovog rodnog barometra

Opis varijable	Akronim	Srednja vrijednost	Standardna devijacija	Min.	Maks.
Mjesečni prihod	*income*	1.769,5	979,6	100	6.000
Logaritam prihoda	*lnincome*	7.347	0,513	4.605	8,700
Žena	*female*	0,501	0,500	0	1
Dob	*age*	51.753	14.860	18	93
Dob na kvadrat	*age2*	2.899,115	1.546,177	324	8.649
Osnovno obrazovanje	*peducat*	0,063	0,243	0	1
Srednje obrazovanje	*seceducat*	0,448	0,497	0	1
Univerzitetsko obrazovanje	*unieduc*	0,489	0,500	0	1
Federacija BiH	*fbih*	0,620	0,485	0	1
Republika Srpska	*rsbih*	0,356	0,479	0	1
Distrikt Brčko u BiH	*dbbih*	0,023	0,151	0	1
Urbano prebivalište	*urban*	0,435	0,496	0	1
U braku	*mARSied*	0,686	0,464	0	1
Politička aktivnost	*act_politics*	0,112	0,315	0	1
Aktivnost u NVO-ima	*act_ngo*	0,138	0,345	0	1
Humanitarna aktivnost	*act_human*	0,176	0,381	0	1
Sportska aktivnost	*act_sport*	0,154	0,361	0	1
Aktivnost sindikata	*act_lunion*	0,164	0,370	0	1
Neformalna aktivnost	*act_inform*	0,128	0,334	0	1
Javni sektor	*empl_public*	0,233	0,423	0	1
Privatni sektor	*empl_private*	0,283	0,451	0	1
Izvan sektora rada	*empl_out*	0,378	0,485	0	1
Nezaposlen	*empl_not*	0,046	0,209	0	1
Poduzetnici	*empl_entr*	0,059	0,237	0	1
Ranjiva kategorija	*vulnerable*	0,330	0,470	0	1

Podaci u Tabeli 1 pokazuju varijacije u prihodima i ključnim individualnim karakteristikama. Uzorak je rodno uravnotežen, pri čemu žene čine otprilike polovinu ispitanika. Prosječna dob je oko 52 godine, sa širokim rasponom od rane odrasle dobi do starosti. Što se tiče obrazovanja, otprilike 45 posto pojedinaca završilo je srednju školu, a oko 49 posto steklo je univerzitetsko obrazovanje, što odražava relativno dobro obrazovani uzorak. Zaposlenost u javnom sektoru čini otprilike 23 posto radne snage.

Također ispitujemo ključne Mincerove (1974.) varijable i parne korelacije između njih kako bismo procijenili potencijalnu prisutnost multikolinearnosti ili preklapajućih objašnjavajućih informacija u modelu. Rezultati pokazuju da je logaritamski prihod umjereno i pozitivno koreliran sa univerzitetskim obrazovanjem i negativno koreliran sa srednjoškolskim obrazovanjem, što je u skladu s očekivanim prinosima od školovanja. Dob i kvadrat dobi pokazuju vrlo visoku korelaciju, što se i očekivalo s obzirom na njihov funkcionalni odnos. Zaposlenost u javnom sektoru slabo je pozitivno povezana s logaritamskim prihodom i negativno korelirana s dobi i srednjoškolskim obrazovanjem. Sveukupno, osim mehaničke korelacije između dobi i kvadrata dobi, struktura korelacije ne ukazuje na značajnu zabrinutost u vezi s multikolinearnošću.

Tabela 2. Parne korelacije između glavnih Mincerovih varijabli

	Logaritamski prihod	*žena*	*dob*	*dob²*	*Srednje obrazovanje*	*Univerzitetsko obrazovanje*	*Javni sektor*
Akronim	***lnincome***	***female***	***age***	***age²***	***secedukat***	***unieduc***	***empl_public***
lnincome	1.000						
Female	−0,055	1.000					
Age	0,016	0,069	1.000				
age2	0,011	0,072	0,987	1.000			
secedukat	−0,356	−0,076	0,001	−0,011	1.000		
unieduc	0,390	−0,009	−0,100	−0,094	−0,882	1.000	
empl_public	0,119	−0,049	−0,165	−0,201	−0,217	0,283	1.000

Nakon diskusije o podacima i provođenja početne procjene, možemo zaključiti da skup podataka pruža solidnu osnovu za empirijsku analizu koja slijedi. Sada ćemo detaljnije predstaviti ekonometrijsku metodologiju i softver korišten u analizi.

5.3 Empirijska metodologija

Kao što je već spomenuto, u ovoj empirijskoj analizi primijenit će se dvije ekonometrijske metodologije. Prva se temelji na klasičnoj teoriji ljudskog kapitala i metodi analize određivanja plata ekonomije rada, dobro utemeljenoj u literaturi od 1980-ih i široko korištenoj u ekonomiji u svom proširenom ili modificiranom obliku. Konkretno, analiza se oslanja na proširenu verziju Mincerove (1974.) funkcije zarade, koja ostaje jedna od najčešće korištenih specifikacija u empirijskoj ekonomiji (Lemieux, 2006.) i podržava širok raspon proširenih modela koji se također mogu prilagoditi ovom istraživanju. Mincerova (1974.) početna specifikacija modela povezuje zaradu sa školovanjem i iskustvom i ima sljedeće oblike:

a. Početni oblik Mincerovog modela

$$ln(w_i)=\alpha+\beta1\times Obrazovanje_i+\beta2\times Iskustvo_i+\beta3\times Iskustvo_i^2+\varepsilon_i$$

b. Prošireni oblik Mincerovog modela

$$ln(w_i)=\alpha+\beta1\times Obrazovanje_i+\beta2\times Iskustvo_i+\beta3\times Iskustvo_i^2+\delta\times Rod_i+\gamma\times X_i+\varepsilon_i$$

$ln(w_i)$ označava logaritam zarade (ili zamjene zarade). U formuli, i označava presječna posmatranja, tj. jedinice analize. Efekt obrazovanja na zaradu procjenjuje se koeficijentom $\beta1$, dok se efekt iskustva ili dobi odražava kroz kombinaciju koeficijenata $\beta2$ i $\beta3$. ε_i je izraz pogreške sa standardnim karakteristikama. Međutim, ovo je početni model koji istraživači rijetko procjenjuju kao konačnu

specifikaciju, jer njegovo proširenje obično prati uzorak i dostupne podatke (Lemieux, 2006). Stoga dolazimo do proširenog modela, koji će također biti procijenjen korištenjem Specifikacije b).

Uz prethodno razrađene dijelove modela, u Specifikaciji b), X_i predstavlja vektor drugih kontrolnih varijabli (npr. sektor, regija i ekonomska aktivnost), dok je Rod_i ključna varijabla od interesa. Koeficijent δ stoga procjenjuje veličinu rodne razlike u platama uzimajući u obzir sve posmatrane karakteristike uključene u model. Ovaj okvir omogućuje procjenu prilagođene rodne razlike u platama koja uzima u obzir sve posmatrane utjecaje u modelu.

Eurostat je preporučio dodatnu metodologiju za izračun prilagođene rodne razlike u platama na temelju dekompozicije Blinder-Oaxaca (BO) (Oaxaca, 1973. i Blinder, 1973.) kako bi se dekomponirale neprilagođene procjene koje su se do 2018. izračunavale na temelju podataka iz Istraživnaja o strukturi zarada (ISZ – eng. SES). Vrijedi spomenuti da se čak i ovaj pristup temelji na izračunavanju i proširivanju standardne Mincerove (1974.) funkcije zarade, te je stoga direktno povezan s prethodno razrađenom metodom (Leythienne i Ronkowski, 2018.). Pristup se provodi u dvije faze: prvo se provodi regresijska analiza kojom se odvajaju jednadžbe zarade za muškarce (M) i žene (W). Model se može izraziti na sljedeći način:

c. Jednadžba zarade za muškarce

$$ln(y_i^M) = \beta_0^M + \sum_{k=1}^{K} \beta_k^M x_{ki}^M + u_i^M$$

d. Jednadžba zarade za žene

$$ln(y_i^W) = \beta_0^W + \sum_{k=1}^{K} \beta_k^W x_{ki}^W + u_i^W$$

gdje $ln(y_i^M)$ i $ln(y_i^W)$ predstavljaju prirodni logaritam satnice za posmatranje i za muškarce (M) i žene (W). Varijable x_{ki}^M i x_{ki}^W gdje je $k = 1,...,K,$, predstavljaju objašnjavajuće varijable koje obuhvaćaju posmatrane lične, radne i poduzetničke karakteristike koje mogu utjecati na logaritam satnice u modelu. Parametri β_0^M i β_0^W označavaju konstantne članove jednadžbi zarade, dok β_k^M i β_k^W predstavljaju procijenjene koeficijente povezane s objašnjavajućim varijablama za muškarce i žene. Članovi u_i^M i u_i^W označavaju članove pogreške za posmatranje i, za koje se pretpostavlja da imaju standardne karakteristike (tj. nezavisno i normalno distribuirane). Dalji detalji o tome kako je model konstruiran mogu se pronaći u Leythienne i Ronkowski (2018), dok mi nastavljamo s konačnom specifikacijom.

Na temelju ovih procijenjenih jednadžbi plata, razlika između prosječnog logaritma satnice za muškarce i žene može se rastaviti na sljedeći način:

e. Konačna jednadžba dekompozicije:

$$ln(\bar{y}^M) - ln(\bar{y}^W) = (\hat{\beta}_0{}^M - \hat{\beta}_0{}^W) + \sum_{k=1}^{K} \bar{x}_k{}^W(\hat{\beta}_k{}^M - \hat{\beta}_k{}^W) + \sum_{k=1}^{K} \hat{\beta}_k{}^M(\bar{x}_k{}^M - \bar{x}_k{}^W)$$

U ovoj dekompoziciji, $ln(\bar{y}^M)$ i $ln(\bar{y}^W)$ označavaju srednji logaritam satnice za muškarce i žene. Izrazi $\bar{x}_k{}^M$ i $\bar{x}_k{}^W$ predstavljaju srednje vrijednosti objašnjavajućih varijabli za muškarce i žene. Dekompozicija dijeli ukupnu rodnu razliku u platama na dvije komponente: objašnjeni dio, koji odražava razlike u uočljivim karakteristikama kao što su obrazovanje, iskustvo, zanimanje ili sektor, i neobjašnjeni dio, koji odražava razlike u prinosima od tih karakteristika, a može obuhvatiti i utjecaj diskriminacije, uključujući i druge neuočene faktore.

Konačno, vrijedi spomenuti da je empirijska analiza nova i započela je pripremom skupa podataka iz Rodnog barometra 2023 za empirijsko modeliranje, uključujući pojedinačni pregled svih varijabli, kao i stvaranje novih varijabli i transformaciju postojećih kako bi se skup podataka pripremio za empirijske modele. Softver STATA 18 koristi se za procjenu regresijskih analiza i dekompozicije, kao i za izračun efekata interakcije i pružanje vizualnih interpretacija gdje je potrebno. Sintaksa STATA-e napisana je ručno i može se dobiti za repliciranje bilo kojeg modela prijavljenog u studiji, dok se specifične naredbe nakon procjene primjenjuju za organiziranje regresijskih rezultata i njihov izvoz u Word ili Excel datoteke [2].

5.4 **Rezultati i analiza**

Ovaj odjeljak predstavlja glavne empirijske rezultate studije. Analiza se provodi u dva koraka. Prvo, procjenjujemo niz funkcija zarade na temelju Mincerovog (1974.) okvira kako bismo ispitali odnos između individualnih karakteristika i prihoda, kao i kako bismo pružili početnu procjenu rodne razlike u platama uslovljenu posmatranim karakteristikama muškaraca i žena. Drugo, primjenjujemo metodologiju dekompozicije Blinder-Oaxaca kako bismo dalje istražili izvore posmatrane rodne razlike u platama odvajanjem dijela objašnjenog razlikama u posmatranim karakteristikama od neobjašnjive komponente (prilagođena razlika). Oba pristupa primjenjuju se na isti skup podataka (UNDP-ov Rodni Barometar, 2024.) i empirijsku specifikaciju uvedenu u prethodnom odjeljku, osiguravajući dosljednost i usporedivost rezultata. Kako bismo provjerili robusnost rezultata, provodimo niz postupaka provjere i procjena, uključujući nove modele s različitim skupovima podataka prikupljenim u novijem razdoblju (tj. RCC, 2025.).

2 Svi empirijski koraci provode se ručno i bez podrške umjetne inteligencije, uključujući pisanje studije, dok se usluge umjetne inteligencije prvenstveno koriste za strukturiranje argumentacije, fino podešavanje jezika i bolje jezične izraze, uključujući i neka poboljšanja vizualnog prikaza rezultata (tj. grafova).

5.4.1. **Rodna razlika u platama - Mincerova funkcija zarade**

Mincerove (1974.) funkcije zarade prilagođene analizi rodne razlike u platama procijenjene su korištenjem podataka UNDP-ovog Rodnog barometra (2024.), koji je presječni skup podataka procijenjen metodom procjene običnih najmanjih kvadrata (OLS). Rezultati regresije prikazani su u Tabeli 3 gdje je nekoliko modela sekvencijalno uvedeno, postepeno dodajući dodatne kontrole najjednostavnijoj Mincerovoj funkciji zarade kako bi se procijenila robusnost ključnih nalaza o varijabli od interesa (*žene)* i stabilnost procijenjene rodne razlike u platama uslovljene tim dodatnim posmatranim veličinama.

Prva specifikacija modela (Model 1) predstavlja početni Mincerov model, gdje se zarade rodno objašnjavaju (*ženski – eng. female)*, dobi (age*, age2)* i obrazovanjem (srednje obrazovanje - *seceducat, univerzitetsko obrazovanje - unieducat)* i početnim oblikom funkcije zarade. Model 2 proširuje ovu specifikaciju uvođenjem kontrola na nivou entiteta za Federaciju BiH (*fbih)* i Republiku Srpsku (*rsbih)* kako bi se uzelo u obzir specifično institucionalno okruženje u BiH i potencijalne regionalne razlike u zaradama. Treba napomenuti da ekonomske razlike između ova dva entiteta često postoje u službenim statistikama, kao i u empirijskim ekonometrijskim studijama. Model 3 dodatno proširuje model dodavanjem varijable koja obuhvaća urbano prebivalište (*urban)*, što nam omogućuje kontrolu prostornih razlika u mogućnostima na tržištu rada, budući da urbana područja obično nude raznolikije mogućnosti zapošljavanja i sektore veće produktivnosti od ruralnih područja. Ovo također uključuje bračni status kako bi se kontrolirale porodične karakteristike (*u braku)* koje mogu utjecati na ishode na tržištu rada i zarade žena, kao što je to slučaj u nekim drugim zemljama u regiji (npr. Kosovo, kako su izvijestili Gashi i Adnett, 2020). Model 4 uključuje indikatore građanskog i društvenog angažmana, uključujući učestvovanje u političkim aktivnostima (*act_politics)*, nevladinim organizacijama (*act_ngo)*, inicijativama za ljudska prava (*act_human)*, sportskim organizacijama (*act_sport)*, sindikatima (*act_lunion)* i neformalnim aktivnostima (*act_inform)*, obuhvaćajući potencijalne efekte društvenih mreža i građanskog učestvovanja na ekonomske prilike. Model 5 dodaje varijable sektora zapošljavanja, razlikujući zaposlenike javnog (*empl_public)* i privatnog sektora (*empl_private)* u odnosu na izostavljenu kategoriju poslovnih ljudi (samozaposlenih ili vlasnika poduzeća), što nam omogućuje da uzmemo u obzir potencijalne sektorske razlike u ishodima prihoda. Model 6 na kraju uključuje status ranjivosti pojedinaca u BiH. Varijabla *vulnerable (ranjivost)* identificira pojedince koji pripadaju barem jednoj ranjivoj grupi, uključujući samohrane roditelje, osobe s invaliditetom, Rome, LGBTI osobe ili interno raseljene osobe. Podsjećamo, zavisna varijabla *lnincome* je logaritamska vrijednost srednje zarade (ukupni neto lični mjesečni prihod), dok koeficijenti na nezavisnim varijablama prikazuju elastičnosti efekata, pri čemu je varijabla *female* varijabla koja obuhvaća rodne razlike u platama nakon kontrole svih posmatranih faktora (1 označava žene, a 0 muškarce).

Tabela 3. Rodna razlika u platama procijenjena u Mincerovoj funkciji zarade

VARIJABLE	(1) lnincome	(2) lnincome	(3) lnincome	(4) lnincome	(5) lnincome	(6) lnincome
female	**-0,139*** **	**-0,139*** **	**-0,136*** **	**-0,130*** **	**-0,129*** **	**-0,124*** **
	(0,0316)	**(0,0317)**	**(0,0316)**	**(0,0322)**	**(0,0322)**	**(0,0321)**
age	0,0174	0,0185*	0,0172	0,0192*	0,0205*	0,0223*
	(0,0108)	(0,0108)	(0,0113)	(0,0115)	(0,0115)	(0,0114)
age2	-0,000170	-0,000181	-0,000166	-0,000187	-0,00020*	-0,00021*
	(0,000119)	(0,000119)	(0,000123)	(0,00012)	(0,000125)	(0,000124)
seceducat	0,586***	0,598***	0,570***	0,573***	0,576***	0,536***
	(0,150)	(0,150)	(0,150)	(0,151)	(0,151)	(0,151)
unieduc	1,006***	1,014***	0,962***	0,963***	0,967***	0,912***
	(0,149)	(0,150)	(0,150)	(0,151)	(0,152)	(0,152)
fbih		0,0386	0,0372	0,0450	0,0444	0,0674
		(0,0994)	(0,0991)	(0,101)	(0,101)	(0,101)
rsbih		0,00170	-0,00240	-0,00285	-0,0110	0,0155
		(0,101)	(0,101)	(0,103)	(0,103)	(0,103)
urban			0,0928***	0,093***	0,099***	0,098***
			(0,0318)	(0,0321)	(0,0321)	(0,0319)
mARSied			-0,0173	-0,0236	-0,0282	-0,0530
			(0,0376)	(0,0378)	(0,0378)	(0,0384)
act_politics				0,0961*	0,0941*	0,0970**
				(0,0496)	(0,0496)	(0,0493)
act_ngo				-0,0343	-0,0339	-0,0196
				(0,0475)	(0,0474)	(0,0473)
act_human				-0,00294	-0,00638	-0,00373
				(0,0412)	(0,0412)	(0,0410)
act_sport				-0,00657	-0,00714	-0,00625
				(0,0413)	(0,0412)	(0,0410)
act_lunion				0,00553	0,0139	0,0153
				(0,0368)	(0,0418)	(0,0416)
act_inform				-0,000421	-0,0120	-0,0132
				(0,0482)	(0,0483)	(0,0481)
empl_public					-0,125**	-0,119**
					(0,0607)	(0,0604)
empl_private					-0,143**	-0,140**
					(0,0558)	(0,0555)
vulnerable						-0,127***
						(0,0397)
Konstanta	6,164***	6,101***	6,140***	6,080***	6,185***	6,190***
	(0,270)	(0,286)	(0,290)	(0,295)	(0,299)	(0,297)
Opažanja	922	922	922	917	917	917
R-kvadrat	0,187	0,188	0,195	0,196	0,202	0,211

Standardne pogreške u zagradama. *** p<0,01, ** p<0,05, * p<0,1

Rezultati osnovnog modela (Model 1) otkrivaju jasnu i statistički značajnu rodnu razliku u platama (koeficijent za *žene)* na najvišom nivou statističke značajnosti (*** p < 0,01), što se zaista odnosi na sve procijenjene modele. Takav robustan statistički efekt sugerira da možemo imati potpuno povjerenje da postoji sistemska razlika u ličnom prihodu između žena i muškaraca nakon što uzmemo u obzir sve uočljive varijable koje čine modele. Ako kvantificiramo ovaj efekt, koeficijent sugerira da žene u prosjeku zarađuju oko 13,9 posto manje od muškaraca , uz održavanje ostalih karakteristika konstantnima. Ova razlika ostaje izuzetno stabilna u svim specifikacijama modela (u rasponu od 12% do 14% u svim modelima), što ukazuje na to da dodatne uočljive individualne karakteristike objašnjavaju samo ograničen dio razlike.

Obrazovanje također pokazuje snažne i dosljedne prinose. Pojedinci sa srednjim obrazovanjem zarađuju otprilike 59 posto više od onih u referentnoj kategoriji obrazovanja (samo osnovno obrazovanje), dok diplomirani studenti zarađuju oko 100 posto više, što naglašava snažnu ulogu akumulacije ljudskog kapitala u oblikovanju ishoda zarade. Dob utječe pozitivno, a kvadrat dobi negativno, što sugerira tipičan obrazac zarade tokom životnog ciklusa u kojem prihod raste s iskustvom prije nego što se kasnije u životu konačno stabilizira, iako ti efekti nisu precizno procijenjeni u posmatranim modelima.

U drugoj specifikaciji (Model 2), rezultati pokazuju da regionalne razlike ne igraju glavnu ulogu u objašnjavanju varijacija u prihodima nakon što se uzmu u obzir individualne karakteristike. Koeficijenti za entitetske varijable (*FBIH* , *RSBIH* , s Brčko Distriktom BiH kao izostavljenom kategorijom) su mali i statistički beznačajni, dok procijenjena rodna razlika u platama ostaje gotovo identična osnovnom rezultatu. To sugerira da se rodna razlika u platama ne može pripisati geografskim razlikama širom zemlje, što je također važan nalaz, tj. ako postoji rodno zasnovana diskriminacija, ona se događa sistematski širom zemlje bez strukturnih razlika između različitih entiteta u BIH.

Treći model (Model 3) dodaje kontrolu za urbano prebivalište i bračni status. Život u urbanom području povezan je s otprilike 9-10 posto većom zaradom , a efekt je statistički značajan i vrlo stabilan u svim modelima. To vjerojatno odražava jače mogućnosti na tržištu rada u urbanim područjima, uključujući veću dostupnost poslova i veću koncentraciju proizvodnih sektora. Osim toga, rezultati pokazuju da bračni status nema statistički značajan utjecaj na zaradu nakon što se uzmu u obzir drugi faktori. Uključivanje ovih varijabli ne utječe na procijenjenu rodnu razliku u platama.

Sljedeći model (Model 4) proširuje analizu uključivanjem indikatora društvenog i građanskog angažmana, uključujući učestvovanje u političkim aktivnostima, nevladinim organizacijama, inicijativama za ljudska prava, sportskim organizacijama, sindikatima i neformalnim aktivnostima. Među tim varijablama, samo je učestvovanje u političkim aktivnostima (*act_politics)* povezano s približno 9-10 posto većom zaradom i ima statistički značajan efekt. To može odražavati ulogu društvenih mreža, utjecaja ili vodećih pozicija koje se mogu pretvoriti u puno bolje ekonomske prilike. Drugi oblici građanskog angažmana ne pokazuju statistički značajne efekte na prihod, što je također zanimljiv nalaz. Uključivanje ovih varijabli ostavlja ključne nalaze uglavnom nepromijenjenima, s rodnom razlikom u platama koja ostaje na otprilike 13 posto .

Peti model uvodi varijable sektora zaposlenosti (Model 5). U ovoj specifikaciji, izostavljena kategorija sastoji se od poduzetnika (samozaposleni ili vlasnici poduzeća), s kojima se uspoređuju zaposlenici javnog i privatnog sektora. Rezultati pokazuju da obje grupe prijavljuju niže zarade u odnosu na poduzetnike: zaposlenici javnog sektora zarađuju oko 12,5 posto manje, dok zaposlenici u privatnom sektoru zarađuju otprilike 14,3 posto manje u prosjeku. Ovaj obrazac vjerojatno odražava veći potencijal prihoda povezan s poduzetničkim ili samozaposlenim aktivnostima. Usprkos uzimanju u obzir razlika u sektorima zapošljavanja, rodna razlika u platama ostaje stabilna na otprilike 13 posto, što potvrđuje da uočena razlika i dalje postoji među različitim oblicima zaposlenja.

Šesti model proširuje specifikaciju uvođenjem varijable koja obuhvaća status ranjivosti (Model 6). Rezultati pokazuju da ranjive osobe, kako je opisano u prethodnom odjeljku - samohrani roditelji, osobe s invaliditetom, Romi, LGBTI osobe i interno raseljene osobe - zarađuju otprilike 12,7 posto manje od svojih kolega koji nisu u ranjivoj grupi, uz održavanje ostalih faktora konstantnima. Ovaj nalaz ukazuje na prisutnost širih strukturnih nedostataka na tržištu rada koji utječu na zarade izvan standardnog ljudskog kapitala i karakteristika povezanih s poslom. Uključivanje ranjivosti neznatno smanjuje procijenjenu rodnu razliku u platama na oko 12,4 posto. Međutim, razlika je i dalje negativna i statistički značajna. To sugerira da, iako status ranjivosti čini mali dio uočenih rodnih razlika, rodno zasnovane razlike u zaradi i dalje postoje čak i nakon kontrole preklapajućih oblika nepovoljnog položaja.

Sveukupno, rezultati sugeriraju da, iako obrazovanje, lokacija, sektor zaposlenja i status ranjivosti igraju važnu ulogu u oblikovanju prihoda u BiH, ovi faktori ne objašnjavaju u potpunosti trajnu rodnu razliku u platama. Čak i nakon kontrole širokog raspona karakteristika, žene i dalje zarađuju znatno manje od muškaraca, što ukazuje na važnost dodatnih strukturnih faktora na tržištu rada koji nisu u potpunosti obuhvaćeni dostupnim podacima. Sada procjenjujemo odvojene modele za muškarce i žene kako bismo vidjeli sistemske efekte u tim pod-uzorcima u poređenju s punim uzorkom.

Tabela 4. Rodna razlika u platama procijenjena u Mincerovoj funkciji zarade u poduzorcima

VARIJABLE	(1) lnincome SVI	(2) lnincome ŽENE	(3) lnincome MUŠKARCI
female	-0,124***	-	-
	(0,0321)		
age	0,0223*	0,0386**	0,00624
	(0,0114)	(0,0178)	(0,0152)
age2	-0,000217*	-0,000331*	-8.95e-05
	(0,000124)	(0,000194)	(0,000164)
seceducat	0,536***	0,0945	0,798***
	(0,151)	(0,216)	(0,209)
unieduc	0,912***	0,514**	1.156***
	(0,152)	(0,218)	(0,211)
fbih	0,0674	0,0867	0,0736
	(0,101)	(0,152)	(0,134)
rsbih	0,0155	0,0243	0,0445
	(0,103)	(0,154)	(0,137)
urban	0,0986***	0,126***	0,0708
	(0,0319)	(0,0446)	(0,0442)
mARSied	-0,0530	-0,110**	0,0430
	(0,0384)	(0,0497)	(0,0587)
act_politics	0,0970**	0,0417	0,126*
	(0,0493)	(0,0763)	(0,0649)
act_ngo	-0,0196	-0,00442	-0,0284
	(0,0473)	(0,0665)	(0,0656)
act_human	-0,00373	-0,00247	-0,00344
	(0,0410)	(0,0599)	(0,0557)
act_sport	-0,00625	0,0631	-0,0411
	(0,0410)	(0,0631)	(0,0541)
act_lunion	0,0153	0,0230	-0,00104
	(0,0416)	(0,0597)	(0,0567)
act_inform	-0,0132	0,0878	-0,0471
	(0,0481)	(0,0775)	(0,0617)
empl_public	-0,119**	-0,00803	-0,180**
	(0,0604)	(0,0915)	(0,0799)
empl_private	-0,140**	-0,0626	-0,181**
	(0,0555)	(0,0849)	(0,0731)
vulnerable	-0,127***	-0,155***	-0,118**
	(0,0397)	(0,0540)	(0,0561)
Konstanta	6.190***	5.894***	6.372***
	(0,297)	(0,479)	(0,389)
Opažanja	917	385	532
R-kvadrat	0,211	0,303	0,198

Standardne pogreške u zagradama. *** p<0,01, ** p<0,05, * p<0,1

Rezultati pokazuju jasne rodne razlike u prinosima od ključnih karakteristika koje sada usporedno uočavamo u punom uzorku te ženskim i muškim poduzorcima. U punom uzorku (ALL), osobe sa srednjim obrazovanjem zarađuju oko 54% više, dok oni sa univerzitetskim obrazovanjem zarađuju oko 91% više od onih s osnovnim obrazovanjem. Međutim, ti se prinosi značajno rodno razlikuju: za žene (eng. FEMALE), srednjoškolsko obrazovanje ne donosi statistički značajan porast prihoda, dok je univerzitetsko obrazovanje povezano s oko 51% većim prihodom; za muškarce (MALE), oba nivoa obrazovanja su snažno nagrađena, pri čemu je srednjoškolsko obrazovanje povezano s oko 80% većim prihodom, a univerzitetsko obrazovanje s oko 116% većim prihodom. Život u urbanim područjima povezan je s oko 10% većim prihodom općenito i 13% većim prihodom za žene, dok efekt za muškarce nije statistički značajan. Učestvovanje u političkim aktivnostima povećava prihod za oko 10% u punom uzorku i 13% za muškarce, ali ne pokazuje značajan efekt za žene. Konačno, pripadnost ranjivoj grupi smanjuje prihod za oko 13% ukupno, s većim smanjenjem za žene (16%) nego za muškarce (12%), što ukazuje na to da ranjivost pogoršava nedostatke u pogledu prihoda, a posebno među ženama.

Tabela 5. Sažetak rodne razlike u platama u rodnim poduzorcima

Karakteristično	Žene (%)	Muškarci (%)	Rodne razlike (žene i muškarci)	Tumačenje
Srednje obrazovanje	~0% (ns)	+80%	**−80 %**	Žene nemaju koristi od srednjoškolskog obrazovanja u poređenju s osnovnoškolskim, dok muškarci imaju značajne koristi od srednjoškolskog obrazovanja.
Univerzitetsko obrazovanje	+51%	+116%	**−65 %**	Žene ostvaruju visoke prinose od visokog obrazovanja, ali mnogo niže od muškaraca
Urbano prebivalište	+13%	~0%	**+13 %**	Žene imaju više koristi od života u urbanim područjima u poređenju s ruralnim područjima nego muškarci
Politički aktivizam	~0% (ns)	+13%	**−13 %**	Samo muškarci ostvaruju prihodovne pogodnosti od političkog aktivizma, ali ne i žene
Ranjiv status	−16%	−12%	**−4 %**	Ranjivost je više nepovoljna za žene nego muškarce, kombinirajući povećani negativni efekt na prihod

Rodna razlika u platama ne odražava se samo u osnovnom smanjenju od oko 12% niže zarade za žene, već i u nejednakim prinosima od ključnih karakteristika. Žene su posebno u nepovoljnom položaju u prinosima od obrazovanja i političkog aktivizma, gdje muškarci imaju veće koristi, dok one obično više dobivaju od života u urbanim područjima. Istovremeno, ranjivost dodatno produbljuje nejednakost, jer ima jači negativan utjecaj na prihode žena u poređenju s muškarcima. Sada prelazimo na dekompoziciju razlike procjenom modela dekompozicije Blinder-Oaxaca.

5.4.2 Rodna razlika u platama - dekompozicija Blinder-Oaxaca

Druga metoda koja se može koristiti za analizu prilagođene rodne razlike u platama, a koja je predstavljena u metodološkom odjeljku, jest dekompozicija Blinder-Oaxaca (BO). Metodologija BO dekomponira razliku na dio koji se može objasniti razlikama u karakteristikama koje utječu na postignuća na tržištu rada (npr. iskustvo i obrazovanje) i neobjašnjeni dio koji je zamjena za potencijalnu diskriminaciju, ali i druge neopažene efekte, te se tumači kao mjera prilagođene rodne razlike u platama. Regresijske funkcije u BO rezultat su prilagođavanja i proširenja standardnih Mincerovih (1974.) funkcija zarade (Leythienne i Ronkowski, 2018.), što prirodno proširuje našu analizu iz prethodnog odjeljka. Konačno, BO nam također daje mogućnost da dobijemo šta bi radnica s prosječnim karakteristikama zaradila da je bila tretirana na isti način kao i tipičan muški radnik (Bazen, 2011.). Stoga se korištenjem ove metodologije dekompozicije otkrivaju tri važne informacije o razlici, koje prikazujemo u sljedećoj tabeli.

Procijenili smo sve prethodne modele (Model 1-6) koji su se pokazali konzistentnima u procjeni veličine rodne razlike u platama. Međutim, kako bismo izbjegli prenatrpano izvještavanje u studiji, rezultate prikazujemo u sažetom obliku u Tabeli 6.

Tabela 6. Prilagođeni RRP procijenjen Blinder-Oaxaca metodom, modeli 1-6

VARIJABLE	Model (1)	Model (2)	Model (3)	Model (4)	Model (5)	Model (6)
group_1	7,371***	7,371***	7,371***	7,368***	7,368***	7,368***
	-0,023	-0,023	-0,023	-0,0231	-0,0231	-0,0231
group_2	7,314***	7,314***	7,314***	7,317***	7,317***	7,317***
	-0,0246	-0,0246	-0,0246	-0,0245	-0,0245	-0,0245
difference	0,0567*	0,0567*	0,0567*	0,0514	0,0514	0,0514
	-0,0337	-0,0337	-0,0337	-0,0337	-0,0337	-0,0337
explained	-0,0827***	-0,0823***	-0,0797***	-0,0788***	-0,0779***	-0,0724***
	-0,0159	-0,016	-0,0165	-0,0173	-0,0175	-0,0179
unexplained	0,139***	0,139***	0,136***	0,130***	0,129***	0,124***
	-0,0304	-0,0305	-0,0303	-0,0311	-0,0309	-0,0308
Opažanja	917	922	922	917	917	917
Neprilagođeni RRP	5,83%	5,83%	5,83%	5,27%	5,27%	5,27%
Objašnjenje RRP-a	-7,94%	-7,90%	-7,66%	-7,58%	-7,50%	-6,99%
Prilagođeni RRP	**14,92%**	**14,92%**	**14,57%**	**13,88%**	**13,76%**	**13,22%**

Standardne pogreške u zagradama. *** p<0,01, ** p<0,05, * p<0,1. Treba napomenuti da su komponente dekompozicije aditivne u logaritamskom smislu, ali ne i u postotnom smislu; stoga se objašnjene i neobjašnjene komponente ne sabiraju tačno u ukupnoj razlici kada se izraze u postotcima (Jann, 2008.)

Neprilagođeni RRP koji dobivamo procjenom modela BO (osnovni model za razradu je Model 6) iznosi 5,3%, što sugerira da muškarci u prosjeku zarađuju oko 5,3% više od žena. Objašnjeni RRP pokazuje razliku između prihoda muškaraca i žena koja je posljedica razlika u prosječnim karakteristikama (Leythienne i Ronkowski, 2018). Objašnjena komponenta iznosi oko -7% i statistički je značajna, što sugerira da bi razlike u uočljivim karakteristikama između muškaraca i žena, ako išta, predvidjele veće zarade za žene za oko sedam posto. Drugim riječima, na temelju faktora kao što su obrazovanje, demografija i druge uočene karakteristike uključene u model, čini se da žene imaju karakteristike koje bi trebale dovesti do većih zarada u odnosu na muškarce na tržištu rada u Bosni i Hercegovini, što nije slučaj u stvarnom životu.

Nasuprot tome, neobjašnjena komponenta iznosi 13,2% i statistički je značajna na najvišem nivou (***p<0,01). Ova komponenta odražava razlike u prinosima od karakteristika između muškaraca i žena koje se smatraju relevantnima. „Neobjašnjena" komponenta mogla bi obuhvaćati rodnu diskriminaciju na tržištu rada, ali i neke lične karakteristike koje se ne uzimaju u obzir, što povećava oprez pri tumačenju (Gashi i Adnett, 2020.). Pozitivna i značajna neobjašnjena komponenta sugerira da žene ostvaruju niže prinose od svojih karakteristika u poređenju s muškarcima, što doprinosi uočenoj rodnoj razlici u platama.

Sveukupno, ovi nalazi ukazuju na to da iako uočljive karakteristike ne objašnjavaju rodnu razliku u zaradi, zapravo bi predvidjele nešto veće zarade za žene, a preostala neobjašnjiva komponenta ide u korist muškaraca. Ovaj obrazac u skladu je s nalazima u literaturi gdje se neobjašnjivi dio razlike u platama često tumači kao odraz strukturnih nejednakosti ili potencijalne diskriminacije na tržištu rada.

Među varijablama uključenim u objašnjenu komponentu dekompozicije (Dodatak 1, Tabela 9), obrazovanje se pojavljuje kao važan (statistički značajan) faktor koji doprinosi razlikama u platama između muškaraca i žena. Rezultati pokazuju da srednjoškolsko obrazovanje ima pozitivan i statistički značajan doprinos objašnjenoj komponenti rodne razlike u platama (koef. = 0,111, p < 0,05). To ukazuje na to da razlike u raspodjeli srednjoškolskog obrazovanja između muškaraca i žena doprinose proširenju uočene razlike u platama u odnosu na referentnu grupu pojedinaca sa samo osnovnim obrazovanjem. To je u skladu s nalazom iz Mincerovog (1973.) modela.

Nasuprot tome, univerzitetsko obrazovanje ima negativan i statistički značajan doprinos (koef. = -0,187, p < 0,01). Drugim riječima, visoko obrazovanje žena pomaže u smanjenju uočene razlike u zaradi. Podsjetimo, iako je efekt visokog obrazovanja za muškarce bio veći u prethodnom modelu, veće učestvovanje žena u Bosni i Hercegovini u visokom obrazovanju (oko 61%) pomaže u smanjenju ukupne razlike[3]. Međutim, ova prednost očito nije dovoljno iskorištena s nižim učestvovanjem na tržištu rada (Braunstein, 2026.).

3 Rodna raspodjela u visokom obrazovanju u uzorku koji koristimo gotovo je identična, tj. 49% za muškarce i 48% za žene. Muškarci dominiraju u srednjoškolskom obrazovanju s 49% u odnosu na 41% za žene, dok žene više dominiraju u osnovnoškolskim grupama s 10% u odnosu na 2% za muškarce. Ova podjela vjerojatno nije reprezentativna za trenutnu raspodjelu obrazovnih grupa. Prema Agenciji za statistiku BiH (2026.), oko 61% učenika su žene, a muškarci više dominiraju u srednjoškolskom obrazovanju.

Sveukupno, ovi nalazi sugeriraju da, osim obrazovanja, većina posmatranih karakteristika uključenih u model ne uzima u obzir rodne razlike u zaradi. To pojačava raniji rezultat da je objašnjena komponenta razlike uveliko uzrokovana obrazovnim razlikama, dok je preostali dio rodne razlike u platama prvenstveno obuhvaćen neobjašnjenom komponentom dekompozicije.

5.5 **Efekti interakcije sa roda**

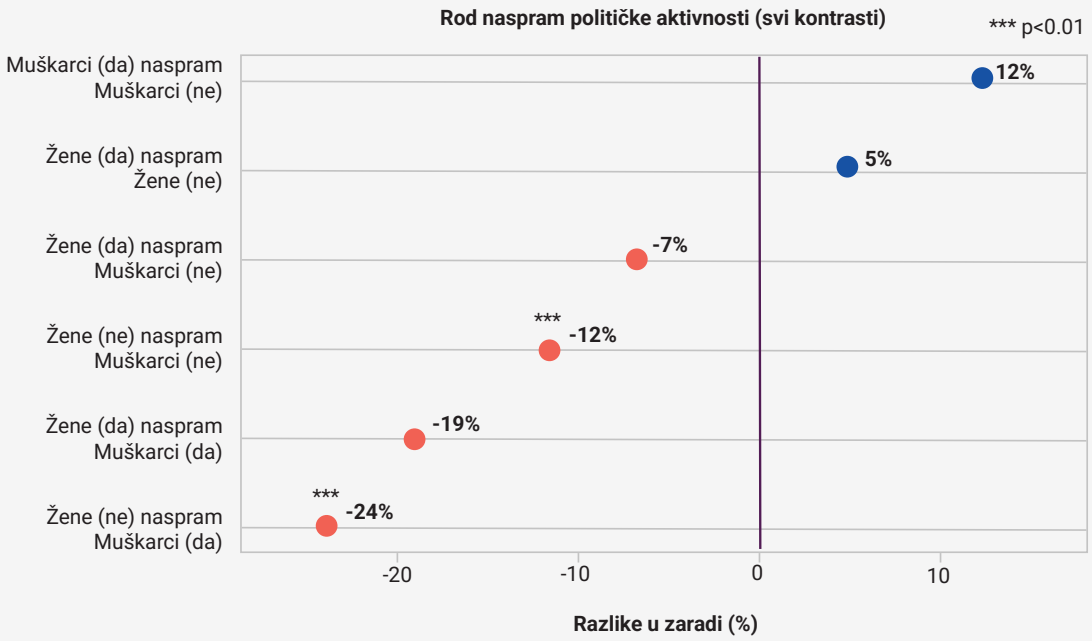
Politike i društveni ishodi rijetko su oblikovani samo jednim faktorom. Umjesto toga, individualne karakteristike često djeluju zajedno i međusobno se pojačavaju ili poništavaju. Na primjer, efekt političkog aktivizma može se razlikovati među muškarcima i ženama ili utjecaj obrazovanja može varirati zavisno o tome gdje pojedinci žive. Ove vrste odnosa nazivaju se interakcijskim efektima, koji obuhvaćaju kako se utjecaj jedne karakteristike kombinira s prisutnošću druge. Ispitivanje tih zajedničkih utjecaja omogućuje nam da bolje razumijemo doživljavaju li određene grupe sistematski različite ishode.

Nadovezujući se na ovaj intuitivni zaključak, analiza se fokusira na interakcije između varijabli za koje se utvrdi da su statistički značajne i teoretski relevantne za razumijevanje rodnih razlika u modelu. Konkretno, analiza procjenjuje kombinacije pojedinaca u relevantnim kategorijama (npr. muškarci *naspram* žena i politički aktivni *naspram* neaktivnih), što nam omogućuje procjenu smjera, veličine i statističke značajnosti kombinirajućih efekata (s tri kombinirane dimenzije dobivamo procjene 28 kombinacija pojedinaca u praksi).

Za izračun efekata interakcije, proširujemo preferiranu proširenu Mincerovu (1974.) specifikaciju (Model 6) s pojmovima interakcije između roda i drugih relevantnih kovarijanti, što nam omogućuje istraživanje kako kombinacije karakteristika oblikuju posmatrane ishode. S obzirom na veliki broj poređenja koja proizlaze iz modela interakcije, svi statistički testovi prilagođeni su za višestruka poređenja pomoću Bonferronijeve korekcije (StataCorp, 2011., str. 1554.). Ovo prilagođavanje osigurava statistički valjano zaključivanje pri istovremenoj procjeni višestrukih efekata interakcije.

Ispitujemo kako rod, obrazovanje, političko učestvovanje, urbano prebivalište i ranjivost u različitim kombinacijama zajedno utječu na uočenu rodnu razliku u platama. Izvještavamo o vizualnim interpretacijama marginalnih efekata (grafikoni s marginalnim efektima) iz dvosmjernih interakcija, dok su trosmjerne interakcije prikazane u tabelama kako bi se izbjegla prekomplicirana prezentacija na grafovima.

Slika 2. Dvosmjerna interakcija roda i političkog učestvovanja

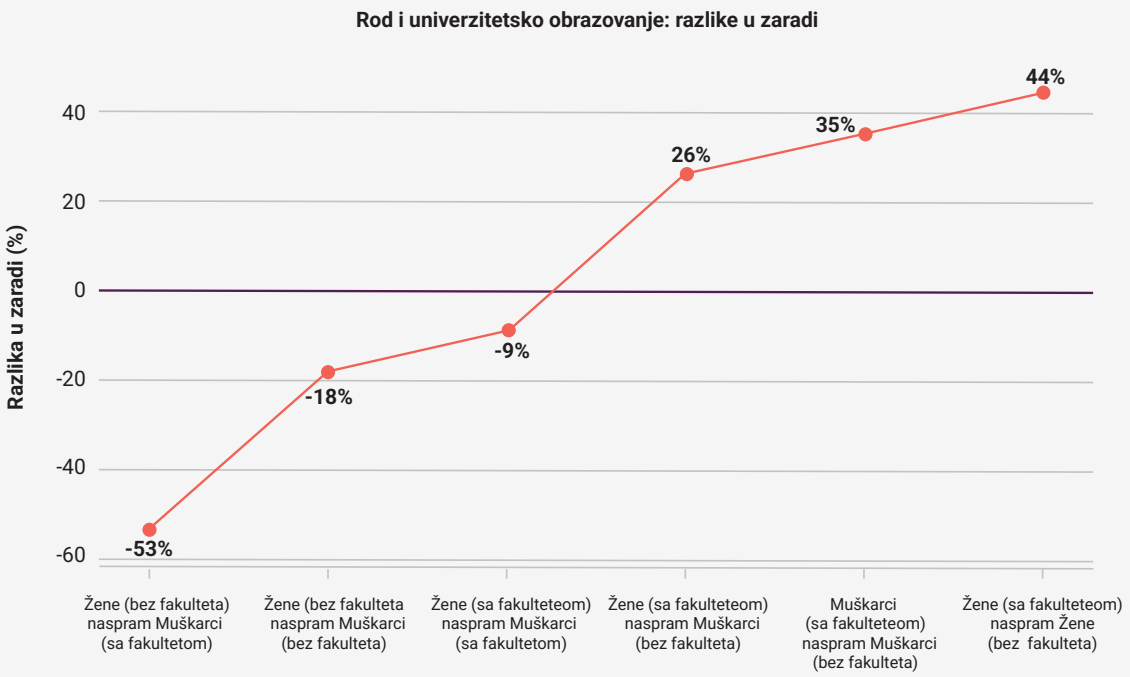


Napomena: statistički značajne kombinacije označene sa *** označavaju p < 0.

Interakcijski efekti između roda i političkog učestvovanja otkrivaju važne razlike u prihodima među grupama. Najveći i statistički značajan kontrast uočen je između politički neaktivnih žena i politički aktivnih muškaraca, pri čemu neaktivne žene u prosjeku zarađuju oko 24 postotna boda manje. Manja, ali i dalje značajna razlika također je pronađena između politički neaktivnih žena i politički neaktivnih muškaraca i iznosi otprilike 12 postotnih bodova, što ukazuje na to da razlike u prihodima postoje čak i među pojedincima koji nisu politički angažirani. Uzeti zajedno , rezultati sugeriraju da politički angažman može ublažiti rodne razlike, ali ih ne uklanja u potpunosti za žene u trenutnim podacima, što naglašava kontinuiranu važnost roda u oblikovanju ishoda studije.

U sljedećoj fazi procjenjujemo osnovni model proširen dvosmjernom interakcijom između roda i obrazovanja. Budući da je obrazovanje izvorno predstavljeno s tri kategorije, broj mogućih kombinacija komplicira i procjenu i interpretaciju. Radi pojednostavljenja analize, procjenjujemo specifikaciju koja razlikuje pojedince s fakultetskim obrazovanjem od onih s nižim stepenom obrazovanja. Vizualni rezultati ove analize interakcije prikazani su u nastavku (samo značajni efekti).

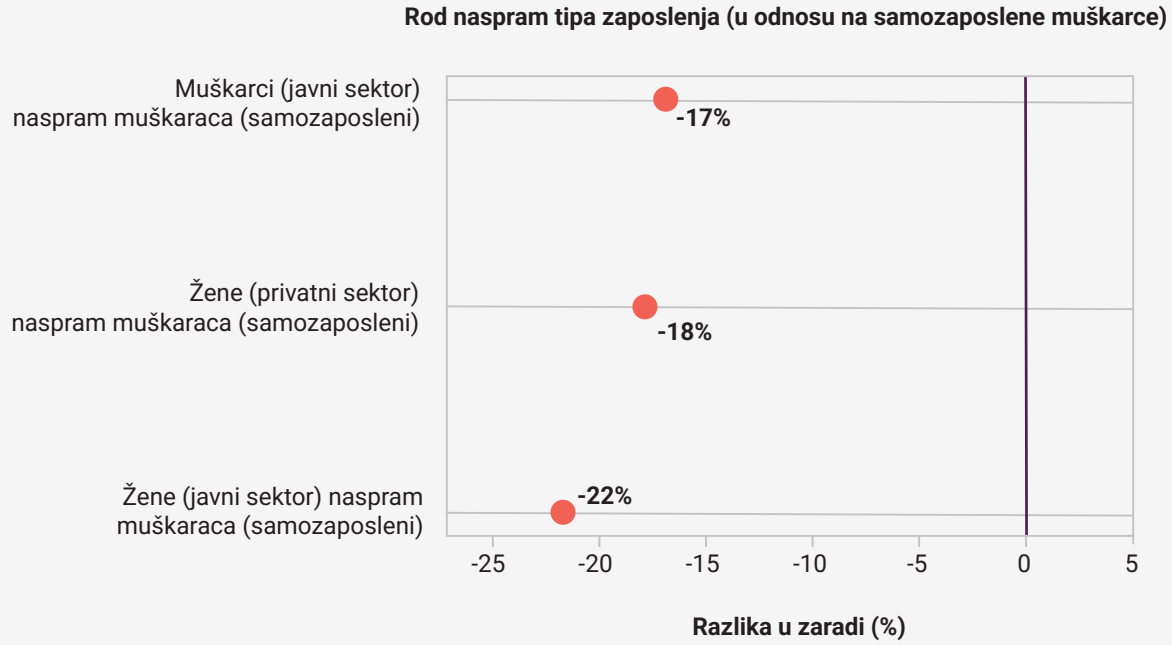
Slika 3. Dvosmjerna interakcija roda i obrazovanja



Interakcija između roda i univerzitetskog obrazovanja otkriva značajne razlike u prihodima među grupama. Najveći kontrast uočen je između žena bez univerzitetskog obrazovanja i muškaraca sa univerzitetskim obrazovanjem, gdje prvi zarađuju otprilike 56 posto manje, što ukazuje na izražen kombinirani nedostatak povezan i sa rodom i s nižim obrazovanjem. Čak i kada se uspoređuju pojedinci s istim nivoom obrazovanja, žene bez univerzitetskog obrazovanja zarađuju oko 18 posto manje od muškaraca bez univerzitetskog obrazovanja, što sugerira da rodne razlike postoje nezavisno o obrazovanju. Istovremeno, univerzitetsko obrazovanje povezano je s izrazito višim nivoima prihoda. Muškarci sa univerzitetskim obrazovanjem zarađuju oko 35 posto više od muškaraca bez univerzitetskog obrazovanja, dok žene sa univerzitetskim obrazovanjem zarađuju oko 44 posto više od žena bez univerzitetskog obrazovanja, što ukazuje na to da visoko obrazovanje znatno poboljšava ishode za oba roda, a posebno za žene. Žene sa univerzitetskim obrazovanjem također zarađuju znatno više od muškaraca bez univerzitetskog obrazovanja (oko 26 posto više), što ističe snažnu ulogu obrazovanja u oblikovanju razlika u prihodima. Sveukupno, ovi rezultati sugeriraju da obrazovanje znatno smanjuje nedostatke u prihodima povezane sa rodom, ali ih ne uklanja u potpunosti, naglašavajući kontinuiranu važnost i roda i obrazovanja u objašnjavanju varijacija u prihodima.

Konačno, procjenjujemo dvosmjerne efekte između roda i zaposlenosti u javnom naspram privatnog sektora (zaposlenost u privatnom sektoru ili vlasnici poduzeća i samozaposleni).

Slika 4. Dvosmjerna interakcija roda i zaposlenosti u javnom sektoru



U skladu s Modelom 6, predviđene margine pokazuju jasnu rodnu razliku u platama koja varira zavisno o sektoru. Rezultati pokazuju da pojedinci u javnom sektoru zarađuju znatno manje od samozaposlenih muškaraca i vlasnika poduzeća (izostavljena kategorija), koji predstavljaju grupu s najvišim primanjima. Žene se suočavaju s najvećim nepovoljnostima, zarađujući otprilike 18% manje u privatnom sektoru i 22% manje u javnom sektoru u odnosu na muške poduzetnike. Istovremeno, muškarci u javnom sektoru također zarađuju oko 17% manje od svojih samozaposlenih kolega. Ovi nalazi sugeriraju da razlike u platama odražavaju ne samo rodne nejednakosti već i razlike u pozicioniranju na radnom mjestu, pri čemu su samozapošljavanje i vlasništvo poduzeća povezani s većim prinosima. Posebno velike razlike za žene ukazuju na to da su one nedovoljno zastupljene u tim bolje plaćenim ekonomskim pozicijama i da od njih ostvaruju manje koristi.

Zatim procjenjujemo trostranu interakciju između roda, obrazovanja i političkog aktivizma. Dobiveni rezultati prikazani su u Tabeli 7, gdje prikazujemo samo statistički značajne kombinacije.

Tabela 7. Bonferronijevi prilagođeni efekti (rod, obrazovanje, političko učestvovanje)

Varijabla / Kontrast	Efekt	Standardna pogreška	t-statistika	p-vrijednost
Žene (1 naspram 0)	-0,127	0,0324	-3,93	0,000
Univerzitetsko obrazovanje (1 naspram 0)	0,389	0,0348	11,18	0,000
Političko učestvovanje (1 naspram 0)	0,092	0,0503	1,82	0,069
Žene × univerzitet × Političko učestvovanje				
(1 0 0) naspram (0 1 1)	-0,665	0,0937	-7,09	0,000
(1 0 0) naspram (0 1 0)	-0,533	0,0568	-9,40	0,000
(1 0 0) naspram (0 0 1)	-0,289	0,0923	-3,13	0,050
(1 0 0) naspram (0 0 0)	-0,186	0,0543	-3,42	0,018
(1 1 0) naspram (0 0 0)	0,271	0,0445	6,10	0,000
(0 1 0) naspram (0 0 0)	0,348	0,0450	7,72	0,000
(0 1 1) naspram (0 0 1)	0,376	0,1130	3,33	0,025
(1 1 0) naspram (1 0 0)	0,457	0,0561	8,14	0,000
(1 1 1) naspram (1 0 0)	0,462	0,1050	4,40	0,000
(0 1 1) naspram (0 0 0)	0,479	0,0871	5,50	0,000

Napomena: Prikazane su samo statistički značajne kombinacije ($p \leq 0,05$; zadržan je granični slučaj pri $p = 0,050$). Kombinacije ishoda kao što su (1 1 1), (1 0 0) predstavljaju različita zajednička stanja trosmjernih ishoda, gdje 1 označava učestvovanje/prisutnost, a 0 označava odsutnost u aktivnosti.

Trostrana interakcija između roda, univerzitetskog obrazovanja i političkog učestvovanja otkriva značajne razlike u prihodima među grupama, što ukazuje na to da te karakteristike zajedno oblikuju ekonomske ishode.

Najveće i statistički najznačajnije razlike uočavaju se pri poređenju žena, bez univerzitetskog obrazovanja koje nisu politički aktivne s privilegiranijim grupama. Na primjer, ova grupa zarađuje znatno manje od muškaraca sa univerzitetskim obrazovanjem i političkim aktivnostima, s razlikom od približno 67 posto, što ukazuje na izražen kumulativni nepovoljan položaj povezan sa rodom, nižim obrazovanjem i nedostatkom političkog angažmana. Slično velika razlika (oko 53 posto) uočava se pri poređenju ove grupe s muškarcima koji imaju univerzitetsko obrazovanje, ali nisu politički aktivni, što sugerira da obrazovanje igra posebno snažnu ulogu u oblikovanju prihoda.

Dalja poređenja pokazuju da ova nepovoljna grupa također zarađuje znatno manje od muškaraca bez univerzitetskog obrazovanja i bez političkog učestvovanja, s razlikom od oko 19 posto, što ukazuje na to da rodne razlike postoje čak i kada su obrazovanje i političko učestvovanje konstantni.

Trosmjerna interakcija između roda, univerzitetskog obrazovanja i ranjivosti također otkriva značajne i sistemske razlike u prihodima, što ukazuje na to da ovi faktori zajednički strukturiraju ekonomske ishode (Tabela 8). Većina tih kombinacija je statistički značajna, a neke od njih detaljnije objašnjavamo.

Tabela 8. Bonferronijevi prilagođeni efekti (rod, obrazovanje , ranjivost)

Varijabla / Kontrast	Efekt	Standardna pogreška	t-statistika	p-vrijednost
Žene (1 naspram 0)	-0,130	0,0323	-4,02	0,000
Univerzitetsko obrazovanje (1 naspram 0)	0,391	0,0348	11,24	0,000
Ranjivi (1 maspram 0)	-0,128	0,0406	-3,16	0,002
Žene × Univerzitet × Ranjivi				
(1 0 1) naspram (0 1 0)	-0,616	0,0861	-7,16	0,000
(1 0 1) naspram (0 1 1)	-0,575	0,1109	-5,18	0,000
(1 0 0) naspram (0 1 0)	-0,535	0,0616	-8,69	0,000
(1 0 0) naspram (0 1 1)	-0,494	0,0938	-5,26	0,000
(1 0 1) naspram (0 0 0)	-0,307	0,0855	-3,59	0,010
(0 0 1) naspram (0 0 0)	-0,252	0,0669	-3,77	0,005
(1 0 0) naspram (0 0 0)	-0,226	0,0607	-3,72	0,006
(1 1 0) naspram (0 0 0)	0,228	0,0471	4,85	0,000
(0 1 1) naspram (0 0 0)	0,268	0,0846	3,16	0,045
(0 1 0) naspram (0 0 0)	0,309	0,0467	6,63	0,000
(1 1 1) naspram (1 0 0)	0,343	0,0859	3,99	0,002
(1 1 1) naspram (0 0 1)	0,369	0,0881	4,19	0,001
(1 1 1) naspram (1 0 1)	0,424	0,1039	4,08	0,001
(1 1 0) naspram (1 0 0)	0,454	0,0617	7,35	0,000
(1 1 0) naspram (0 0 1)	0,480	0,0669	7,18	0,000
(0 1 1) naspram (0 0 1)	0,520	0,0965	5,39	0,000
(1 1 0) naspram (1 0 1)	0,535	0,0864	6,19	0,000
(0 1 0) naspram (0 0 1)	0,562	0,0666	8,43	0,000

Napomena: Prikazane su samo statistički značajne kombinacije ($p \leq 0,05$; zadržan je granični slučaj pri $p = 0,050$).

Najizraženiji nepovoljniji položaj uočen je među ženama, bez univerzitetskog obrazovanja koje pripadaju ranjivoj kategoriji. Ova grupa zarađuje znatno manje od privilegiranijih grupa. Na primjer, u poređenju s muškarcima sa univerzitetskim obrazovanjem koji nisu ranjivi, njihov je prihod niži za otprilike 62 posto, dok je razlika i dalje slično velika (oko 57 posto) u poređenju s muškarcima sa univerzitetskim obrazovanjem koji su ranjivi. Ovi nalazi ukazuju na snažan kumulativni nepovoljan položaj povezan sa rodom, nižim obrazovanjem i ranjivošću.

Slično tome, žene bez univerzitetskog obrazovanja, koje nisu klasificirane kao ranjive, također doživljavaju značajne gubitke u prihodima u odnosu na visokoobrazovane muškarce, s razlikama od otprilike 53 do 49 posto, što pojačava dominantnu ulogu obrazovanja u oblikovanju nejednakosti u prihodima.

Čak i u poređenju s osobama bez univerzitetskog obrazovanja koje nisu ranjive, grupe u nepovoljnom položaju i dalje pokazuju znatno niže nivoe prihoda. Na primjer, ranjive žene bez univerzitetskog obrazovanja zarađuju oko 31 posto manje od osoba u osnovnoj grupi, dok žene koje nisu ranjive i nemaju univerzitetsko obrazovanje zarađuju otprilike 23 posto manje, što ukazuje na to da i rod i ranjivost nezavisno doprinose ekonomski nepovoljnom položaju.

Obrazovanje dosljedno ostaje ključni pokretač nejednakosti. Na primjer, osobe sa univerzitetskim obrazovanjem zarađuju otprilike 45 posto više od svojih kolega bez univerzitetskog obrazovanja unutar usporedivih uslova ranjivosti, a u nekim poređenjima uočene su čak i veće prednosti (do 53–56 posto). Ovi rezultati naglašavaju da je obrazovanje najmoćniji pojedinačni faktor, dok rod i ranjivost dodatno pojačavaju ili pogoršavaju nejednakosti.

Sveukupno, rezultati interakcije sugeriraju da obrazovanje igra centralnu ulogu u oblikovanju razlika u prihodima, dok ranjivost dodatno stratificira ishode među grupama. Najveće razlike u prihodima pojavljuju se tamo gdje se preklapaju višestruke nepovoljnosti, poput ženskog spola, nedostatka univerzitetskog obrazovanja i ranjivosti, što ističe izražen kumulativni nedostatak. Istovremeno, univerzitetsko obrazovanje znatno poboljšava izglede za prihode u svim grupama i ublažava neke od negativnih efekata povezanih s ranjivošću, iako ne uklanja u potpunosti razlike povezane sa rodom i ranjivošću, dajući više prednosti muškarcima u odnosu na žene.

5.6 **Analiza robusnosti**

Kako bismo procijenili stabilnost procijenjenih modela, proveli smo niz provjera robusnosti koje se obično koriste u primijenjenim ekonomskim istraživanjima. Budući da Model 6 služi kao preferirana specifikacija za interpretaciju, svi testovi robusnosti provedeni su korištenjem ovog modela kao osnovne vrijednosti.

Prvo smo procijenili modele OLS (Mincerovi modeli 1-6) s robusnim i klaster-robusnim standardnim pogreškama, koristeći općine u BiH kao klastere kako bismo dobili konzervativniji statistički zaključak u kojem su općine tretirane kao zasebni klasteri. Procijenjeni efekt roda ostao je nepromijenjen u oba slučaja, dok su koeficijenti ostalih varijabli također ostali konzistentni i po veličini i po značajnosti.

U sljedećem koraku procijenili smo specifikaciju koja uključuje fiksne efekte općina u model za sve općine u Bosni i Hercegovini. Ova specifikacija je znatno veća, sadrži više od 150 varijabli i stoga služi prvenstveno kao ispitivanje robusnosti. Procijenjeni efekti ostali su konzistentni, statistički značajni i negativni, s tim da se efekt roda blago povećao na približno 15 posto.

Zatim smo procijenili najjednostavniju specifikaciju koja isključuje varijable koje su bile statistički neznačajne u osnovnom modelu (Model 6). Osnovne Mincerove (1974.) varijable su zadržane, dok su regionalni indikatori, bračni status i varijable povezane s aktivnošću koje su se pokazale neznačajnima uklonjene. Procijenjeni efekt roda ostao je stabilan na približno 12 posto, što ukazuje na to da glavni rezultati nisu potaknuti uključivanjem dodatnih kontrola.

Konačno, proveli smo skup dijagnostičkih testova modela, uključujući testove funkcionalnog oblika i heteroskedastičnosti. Model 6 nema problema s heteroskedastičnošću podataka, dok je test Ramsey RESET za funkcionalni oblik dobio p-vrijednost na nivou od 0,09, što je prihvatljivo na nivou statističke značajnosti od 5% i gotovo 10%. Specifikacija koja ima puno bolji funkcionalni oblik je ona kada isključimo varijable povezane sa zaposlenjem. Ipak, procijenjeni rodni efekt ostao je praktički nepromijenjen na oko 1,2 posto, a koeficijenti ostalih varijabli razlikovali su se samo marginalno. Budući da status zaposlenja predstavlja važan objašnjavajući faktor, zadržavamo sveobuhvatniju specifikaciju za interpretaciju, priznajući ovaj kompromis, a istovremeno napominjemo da glavni zaključci ostaju dosljedni u obje specifikacije.

Kao dodatnu provjeru robusnosti, procijenili smo reducirani model (Model 6) korištenjem dekompozicije Blinder-Oaxaca. Rezultati su ponovo bili u potpunosti u skladu s glavnim nalazima. Isto vrijedi i kada koristimo podatke RCC (2025), glavne poruke o veličini rodne razlike u platama se ne mijenjaju.

Sveukupno, ove provjere robusnosti potvrđuju stabilnost i pouzdanost procijenjenih rezultata. Zbog prostora, detaljne procjene nisu ovdje navedene, ali su dostupne na zahtjev.

6. ZAKLJUČAK

Ova studija pruža prvu sveobuhvatnu analizu rodne razlike u platama u Bosni i Hercegovini koja integrira i neprilagođene i prilagođene metode procjene korištenjem primarnih i reprezentativnih podataka iz UNDP-ovog Rodnog barometra 2024. Kombiniranjem regresija zarada tipa Mincer s dekompozicijskim pristupom Blinder-Oaxaca, analiza nudi robusno i višedimenzionalno razumijevanje rodnih razlika u platama u zemlji. Važno je napomenuti da je studija uokvirena unutar pristupa Equanomics, holističke i politički orijentirane metodologije razvijene kroz saradnju između UNDP-a u Bosni i Hercegovini, Agencije za ravnopravnost spolova Bosne i Hercegovine pri Ministarstvu za ljudska prava i izbjeglice Bosne i Hercegovine i Foruma žena za razvoj (WF4D). Ovaj okvir integrira konvencionalnu ekonomsku analizu s rodno osjetljivim perspektivama, uzimajući u obzir dinamiku tržišta rada specifičnu za zemlju, institucionalne strukture i društvene norme koje oblikuju rodne nejednakosti. Utemeljivanjem analize na Eurostatovoj metodologiji neprilagođene rodne razlike u platama i njezinim proširenjem prilagođenim modelima i primarnim podacima, studija postiže i metodološku strogost i snažnu političku relevantnost.

Nalazi otkrivaju da je neprilagođena rodna razlika u platama u Bosni i Hercegovini relativno skromna, u rasponu od 5% do 8%, zavisno o pristupu procjene. Međutim, kada se uzmu u obzir razlike u uočljivim karakteristikama, prilagođena rodna razlika u platama znatno se povećava na približno 13%. To implicira da žene efektivno zarađuju ekvivalentno mjesec i pol manje godišnje u poređenju s muškarcima, što naglašava da jednostavno poređenje prosječne zarade obično podcjenjuje stvarni obim rodnih razlika. Rezultati jasno pokazuju da su rodne razlike u platama djelomično skrivene u neprilagođenim mjerama i postaju izraženije kada se uzmu u obzir strukturni faktori. Slijedom toga, neprilagođene indikatore rodne razlike u platama treba tumačiti s oprezom i u kontekstu politike i u istraživačkom kontekstu.

Empirijski rezultati u svim specifikacijama modela dosljedno potvrđuju prisutnost statistički značajne rodne razlike u platama koja ostaje izrazito stabilna čak i nakon progresivne kontrole obrazovanja, demografskih karakteristika, faktora tržišta rada, statusa ranjivosti i društvenog angažmana. Postojanost rodnog efekta u svih šest modela sugerira da uočljive karakteristike objašnjavaju samo ograničen dio razlike u zaradi. Ovaj nalaz dodatno je potkrijepljen analizom dekompozicije, koja pokazuje da je većina rodne razlike u platama uzrokovana razlikama u prinosima od karakteristika, a ne razlikama u samim karakteristikama.

Među posmatranim faktorima, obrazovanje, prebivalište u urbanom području, status ranjivosti i političko učestvovanje pojavljuju se kao najvažniji u oblikovanju razlika u prihodima. Obrazovanje pokazuje snažne i dosljedne prinose; međutim, evidentne su važne rodne asimetrije. Žene nemaju koristi od srednjoškolskog obrazovanja u istoj mjeri kao muškarci, a prinosi od visokog obrazovanja također su niži za žene. To sugerira da, usprkos usporedivim ili višim obrazovnim postignućima, žene nisu jednako nagrađene na tržištu rada. Lokacija također igra značajnu ulogu, pri čemu je prebivalište u urbanom području povezano s višim primanjima. Važno je napomenuti da žene imaju više koristi od urbanih okruženja, što ukazuje na relativno povoljnije uslove na tržištu rada

u gradovima. Međutim, ta prednost nije dovoljna da bi se nadoknadila ukupna rodna razlika u platama.

Analiza nadalje naglašava važnost društvenih i institucionalnih faktora. Učestvovanje u političkim aktivnostima povezano je s višim primanjima, no taj efekt prvenstveno pokreću muškarci, što sugerira rodno uslovljen pristup mrežama, utjecaju i liderskim mogućnostima. Istovremeno, status ranjivosti (obuhvata grupe poput samohranih roditelja, osoba s invaliditetom, Roma, LGBTI osoba i interno raseljenih osoba) značajno smanjuje zaradu. Ova nepovoljnost je izraženija za žene, što ukazuje na preklapajuće i složene nepovoljnosti. Interakcijski efekti potvrđuju da se određene grupe žena suočavaju s posebno nepovoljnim uslovima na tržištu rada, gdje se niži povrati od obrazovanja, ograničen pristup mrežama s visokim povratom i veća izloženost ranjivosti kombiniraju kako bi stvorili kumulativni nedostatak. Ovi nalazi naglašavaju važnost usvajanja intersekcijske perspektive u analizi rodnih nejednakosti.

Osim temeljne empirijske analize, studija smješta svoje nalaze u šire strukturne transformacije tržišta rada, posebno zelenu tranziciju i digitalizaciju. Dokazi UNDP-a i OECD-a (2025.) te Izvještaji UNDP-a o ljudskom razvoju (2025.) pokazuju da sektori u nastajanju, a posebno zelene industrije, područja STEM-a i zanimanja povezana s umjetnom inteligencijom, mijenjaju strukture prihoda, ali i riskiraju pojačavanje postojećih rodnih nejednakosti. Zelena radna mjesta, iako još uvijek predstavljaju relativno mali udio ukupne zaposlenosti, povezana su s većom produktivnošću i potencijalom plata. Međutim, žene su i dalje nedovoljno zastupljene, čineći samo oko jedne trećine zaposlenosti u tim sektorima. Ovaj nejednak pristup potaknut je profesionalnom segregacijom, ograničenim učestvovanjem u tehničkim područjima i strukturnim preprekama poput nejednakog pristupa obrazovanju STEM, odgovornostima njege i ograničenim mogućnostima napredovanja u karijeri.

Slično tome, u kontekstu umjetne inteligencije i digitalne transformacije, trajne rodne razlike u pristupu digitalnim vještinama i korištenju tehnologije dodatno ograničavaju učestvovanje žena u visoko plaćenim sektorima usmjerenim na budućnost. Žene su značajno nedovoljno zastupljene u STEM obrazovanju i područjima povezanim s umjetnom inteligencijom te je manja vjerojatnost da će koristiti alate umjetne inteligencije u profesionalnim okruženjima. Ovi obrasci pojačavaju rodno uslovljenu digitalnu razliku i ograničavaju pristup žena novim ekonomskim prilikama. U Bosni i Hercegovini, ako će biti prisutna slična strukturna ograničenja, ta će dinamika vjerojatno imati važne implikacije na buduće rodne razlike u platama, budući da nismo mogli kontrolirati te efekte u našim empirijskim modelima.

Sveukupno, nalazi ukazuju na to da rodne razlike u platama u Bosni i Hercegovini nisu isključivo rezultat diskriminacije u platama unutar zanimanja, već su duboko ukorijenjene u strukturnim nejednakostima povezanim s prinosom od obrazovanja, sektorima, vještinama i prilikama. Bez ciljanih intervencija, tekuće ekonomske transformacije, uključujući zelenu tranziciju i digitalizaciju, mogu replicirati ili čak pogoršati postojeće rodne nejednakosti.

Kao zaključak, ova studija pruža snažne dokaze da su rodne razlike u platama u Bosni i Hercegovini i trajne i strukturno ukorijenjene. Dok neprilagođene mjere sugeriraju relativno male rodne razlike, dublja i metodološki robusna analiza otkriva značajne razlike nakon što se uzmu u obzir uočljive karakteristike. Rješavanje ovih nejednakosti zahtijeva sveobuhvatan, na dokazima utemeljen i intersektorski pristup politici koji integrira rodna razmatranja u šire ekonomske i tržišne politike.

7. IMPLIKACIJE ZA POLITIKE

Empirijski nalazi ove studije pružaju jasne dokaze da su rodne razlike u platama u Bosni i Hercegovini trajne, strukturno ukorijenjene i nisu u potpunosti objašnjene razlikama u uočljivim karakteristikama. Rezultati pokazuju da su razlike prvenstveno uzrokovane nejednakim prinosima od obrazovanja, segmentacijom tržišta rada, ograničenim pristupom sektorima s višim platama i preklapajućim oblicima nepovoljnog položaja. Istovremeno, nove ekonomske transformacije, posebno u zelenim, digitalnim i sektorima vođenim umjetnom inteligencijom, nose rizik da pojačaju te nejednakosti ako se ne riješe. U tom kontekstu, smanjenje rodne razlike u platama zahtijeva sveobuhvatan, na dokazima utemeljen pristup politici koji istovremeno poboljšava mjerenje, rješava strukturne prepreke i potiče inkluzivno učestvovanje u svim segmentima tržišta rada. Sljedeće preporuke direktno su utemeljene na ovim nalazima i imaju za cilj podržati pravednije i održivije ekonomske ishode.

1. **Poboljšati kvalitetu podataka i mjerenje za politike rodne ravnopravnosti temeljene na dokazima!**

Značajne varijacije u procjenama rodne razlike u platama u različitim studijama naglašavaju potrebu za jačom i koherentnijom bazom dokaza. Donositelji politika trebali bi dati prioritet razvoju usklađenih, rodno razvrstanih podataka o tržištu rada koji omogućuju i neprilagođenu i prilagođenu analizu zarada. To uključuje prikupljanje detaljnih informacija o radnom vremenu, vrsti zaposlenja, sektoru, zanimanju, prekidima karijere, obavezama njege i neformalnim ekonomskim aktivnostima. Jačanje sistema podataka ključno je za tačno identificiranje pokretača nejednakosti i osiguravanje da su intervencije politika efektivno usmjerene i praćene.

2. **Institucionalno ciljati jednake prinose od obrazovanja na tržištu rada!**

Nalazi otkrivaju da obrazovanje ne donosi jednake prinose ženama i muškarcima, usprkos tome što žene često postižu slične ili više nivoe obrazovanja. Žene imaju manje koristi od srednjoškolskog obrazovanja i imaju niže prinose od visokog obrazovanja, što ukazuje na to da problem nije u pristupu obrazovanju, već u načinu na koji se ono nagrađuje na tržištu rada. Stoga bi se politike trebale fokusirati na osiguravanje jednakih prinosa od obrazovanja rješavanjem diskriminacije pri zapošljavanju i napredovanju, poboljšanjem pristupa bolje plaćenim zanimanjima i smanjenjem profesionalne i sektorske segregacije. Omogućavanje ženama da u potpunosti pretvore svoja obrazovna postignuća u zaradu ključno je za smanjenje rodne razlike u platama.

3. Promovirati mogućnosti zapošljavanja i jednaku platu za žene, a posebno u ruralnim područjima!

Nalazi ističu važnost poboljšanja pristupa kvalitetnim mogućnostima zapošljavanja, a posebno u ruralnim područjima gdje su strukturne barijere izraženije. Potreban je pristup politike utemeljen na lokaciji kako bi se riješila ograničenja poput ograničene mobilnosti, slabije potražnje za radnom snagom i ograničenog pristupa njege za djecu i uslugama. Proširenje mogućnosti zapošljavanja, poboljšanje lokalne infrastrukture i podrška prelazu u stabilne i dobro plaćene poslove ključni su za omogućavanje punog učestvovanja žena na tržištu rada.

4. Ciljati posebno ranjive žene kroz inkluzivne politike tržišta rada!

Studija pokazuje da ranjivost značajno pojačava rodno uslovljene nedostatke u prihodima. Stoga bi politike trebale usvojiti intersekcijski pristup i pružiti ciljanu podršku ranjivim ženama putem prilagođenih programa tržišta rada, razvoja vještina, usluga zapošljavanja i ojačane socijalne zaštite. Rješavanje preklapajućih nepovoljnosti je ključno kako bi se osiguralo da najmarginaliziranije grupe ne budu zapostavljene.

5. Jačati integraciju žena u politiku, vodstvo i umrežavanje!

Ograničena politička aktivnost žena, prisustvo na vodećim pozicijama i u profesionalnim mrežama smanjuju njihovu sposobnost da iskoriste bolje plaćene prilike. Nalazi pokazuju da je političko učestvovanje povezano s većim zaradama za muškarce, dok žene ne ostvaruju slične dobitke u zaradi, što ukazuje na nejednak pristup mrežama s visokim povratom i kanalima utjecaja. Ova asimetrija naglašava važnost jačanja zastupljenosti žena u političkim procesima i procesima donošenja odluka, kao i poboljšanja njihovog pristupa profesionalnim mrežama koje olakšavaju napredovanje u karijeri. Osiguravanje uključivanja žena u ta područja ključno je za postizanje pravednijih ishoda na tržištu rada.

6. Integrirati rodnu ravnopravnost u zelenu tranziciju STEM!

Implikacija trenutnih globalnih studija UNDP-a jeste da zelena tranzicija predstavlja i prilike i rizike za rodnu ravnopravnost. Bez ciljane intervencije, ona može replicirati ili produbiti postojeće nejednakosti. Donositelji politika trebali bi integrirati rodna razmatranja u strategije zelene tranzicije podržavajući učestvovanje žena u zelenim radnim mjestima putem osposobljavanja, prekvalifikacije i mjera uključivanja na tržište rada. Istovremeno, potrebno je poboljšano praćenje rodne razlike u platama unutar zelenih sektora kako bi se osigurala pravedna raspodjela koristi od tranzicije.

7. Smanjiti digitalnu rodnu razliku u području umjetne inteligencije i tehnologije!

Širenje digitalnih tehnologija i umjetne inteligencije zahtijeva ciljane politike za sprječavanje novih oblika rodne nejednakosti. Manja upotreba alata umjetne inteligencije od strane žena i nedovoljna zastupljenost u digitalnim zanimanjima naglašavaju potrebu za proširenim pristupom osposobljavanju za digitalne vještine, učenju na radnom mjestu i mogućnostima prekvalifikacije. Osiguravanje učestvovanja žena u digitalnoj transformaciji ključno je za promociju inkluzivnog ekonomskog rasta.

8. Poboljšati institucionalni okvir za pravedna i transparentna tržišta rada!

Održivi napredak zahtijeva snažne institucionalne okvire koji promoviraju transparentnost, odgovornost i jednake mogućnosti. Kreatori politika trebali bi poboljšati provedbu propisa o jednakoj plati i borbi protiv diskriminacije, promovirati transparentnost plata i podržavati pravedne prakse zapošljavanja i napredovanja. Jačanje institucionalnih kapaciteta ključno je za rješavanje strukturnih nejednakosti i osiguravanje da su rezultati na tržištu rada pravedni i inkluzivni.

8. PREDNOSTI, OGRANIČENJA I PRIJEDLOZI ZA BUDUĆA ISTRAŽIVANJA

Ova studija nudi nekoliko važnih prednosti. Prvo, pruža prvu sveobuhvatnu analizu koja predstavlja i prilagođene i neprilagođene procjene rodne razlike u platama, kombinirajući modele funkcija zarade s metodama dekompozicije kako bi se ispitali izvori razlike u platama u Bosni i Hercegovini. Drugo, analiza koristi širok raspon naprednih ekonometrijskih tehnika i statističkih testova, uključujući sistematsko ispitivanje efekata interakcije, što omogućuje dublje i nijansiranije istraživanje rodne razlike u platama. Na kraju, robusnost nalaza je ojačana korištenjem dva nezavisna skupa podataka prikupljena u Bosni i Hercegovini od strane različitih organizacija, što omogućuje provjeru stabilnosti rezultata i potvrđuje konzistentnost procijenjene rodne razlike u platama u svim izvorima podataka.

Usprkos svojim doprinosima, studija je podložna nekoliko ograničenja koja se prvenstveno odnose na dostupne podatke. Prvo, analiza se oslanja na presječne podatke iz UNDP-ovog Rodnog barometra (2024.), koji ne dopušta praćenje pojedinaca tokom vremena ili ispitivanje dinamičkih promjena u zaradama i rezultatima na tržištu rada. Osim toga, podaci nisu najnoviji, što znači da su se neki događaji mogli dogoditi u posljednje dvije do tri godine, iako je malo vjerojatno da će predstavljati velike strukturne promjene na tržištu rada.

Još jedno ograničenje odnosi se na mjerenje prihoda. Zarade se prikazuju u kategoričkim rasponima, a ne kao kontinuirane vrijednosti, što zahtijeva korištenje srednjih vrijednosti unutar raspona prihoda za približnu procjenu zarade. Iako ovaj pristup omogućuje kvantitativnu analizu, on može smanjiti preciznost procijenjenih efekata u poređenju s analizama temeljenim na kontinuiranim podacima o prihodu. Skupu podataka također nedostaje nekoliko potencijalno relevantnih varijabli koje bi mogle dodatno obogatiti analizu, kao što su detaljne informacije o vrsti ugovora, preciznije sektorske klasifikacije (uključujući STEM i zelenu ekonomiju) i precizniji indikatori radnih mjesta ili hijerarhije zanimanja.

Ograničenje ove studije jest to što ne razlikuje rodne razlike u platama izračunate korištenjem satnice i mjesečne zarade. Analiza se oslanja isključivo na mjesečne mjere prihoda, koje mogu

djelomično obuhvatiti razlike u učestvovanju na tržištu rada i radnom vremenu, a posebno niže prosječne radne sate među ženama. Kao rezultat toga, procijenjena rodna razlika u platama može odražavati ne samo razlike u platama već i varijacije u intenzitetu zaposlenosti, što potencijalno dovodi do precjenjivanja čiste nejednakosti plata.

Buduća istraživanja mogla bi proširiti ovu analizu u nekoliko važnih smjerova. Prvo, sveobuhvatnije prikupljanje podataka bilo bi vrijedno u prevladavanju nekih ograničenja povezanih s izostavljenim varijablama. Konkretno, buduća istraživanja mogla bi uključiti detaljnije informacije o vrstama ugovora, radnim mjestima i preciznijim sektorskim klasifikacijama (kao što su STEM i poslovi u zelenoj ekonomiji), kao i kontinuirane mjere prihoda. Takva poboljšanja omogućila bi precizniju procjenu odrednica rodne razlike u platama i pružila dublji uvid u dinamiku tržišta rada.

Drugo, iako se ova studija fokusira na rodnu razliku u platama, šire razumijevanje dugoročne rodne nejednakosti imalo bi koristi od ispitivanja rodne razlike u bogatstvu. Za razliku od zarada, bogatstvo obuhvaća kumulativne efekte ishoda na tržištu rada, štednje, vlasništva nad imovinom i međugeneracijskih transfera tokom životnog vijeka. Analiza rodnih razlika u bogatstvu stoga bi pomogla otkriti dublje i trajnije strukturne nejednakosti koje možda nisu u potpunosti vidljive kada se fokusiramo isključivo na prihod.

REFERENCE

Agencija za statistiku Bosne i Hercegovine (ASBIH) (2024). Istraživanje o strukturi zarada 2022. – Konačni podaci. Prvo izdanje, Demografija i socijalna statistika, br. 1, Sarajevo, 24. decembar 2024. Sarajevo: Agencija za statistiku Bosne i Hercegovine.

Agencija za statistiku Bosne i Hercegovine (ASBiH) (2026). Žene i muškarci u Bosni i Hercegovini. TB03 tematski bilten. Sarajevo: ASBiH.

Bazen, S. (2011). *Ekonometrijske metode za ekonomiju rada* . Oxford: Oxford University Press.

Blinder, AS (1973). Diskriminacija u platama: Reducirani oblik i strukturne procjene. Journal of Human Resources 8(4): 436–455.

Efendić, A. (2025). Rodno uslovljena neformalnost u institucionalnoj ekonomiji: Dokazi iz Zapadnog Balkana. *Bulleting of Economic Studies* 1: 26.

Efendić, A. i Ledeneva, A. (2020). Važnost umrežavanja: troškovi neformalnog umrežavanja na Zapadnom Balkanu. *Economic Systems* 44 (4): 1-14.

Efendić, A. i Pugh, G. (2018). Utjecaj etničke raznolikosti na prihod – empirijsko istraživanje korištenjem podataka ankete iz post-konfliktnog okruženja. *Economics: The Open-Access, Open-Assessment E-Journal* 12 (2018.-17.): 1–34.

Efendić, A., Kovač, D. i Shapiro, NJ (2022). Izloženost sukobima, migracijama i dugoročnoj nejednakosti u obrazovanju i prihodima: Dokazi iz Bosne i Hercegovine. *Defence and Peace Economics* 34 (8): 1003-1017.

Europska unija (2019.). *Direktiva (EU) 2019/1158 Europskog parlamenta i Vijeća od 20. juna 2019. o ravnoteži između poslovnog i privatnog života roditelja i njegovatelja te o stavljanju izvan snage Direktive Vijeća 2010/18/EU.* Službeni list Europske unije.

Gashi, A. i Adnett, N. (2020.). Jesu li žene na Kosovu zaista plaćene više od muškaraca? Uklanjanje dokaza. *Časopis za ekonomiju i poslovanje jugoistačne Europe 15* (2): 83-95.

ILO (2019.) Poslovni argumenti za promjenu. Žene u poslovnom menadžmentu. Ženeva: ILO.

Međunarodna organizacija rada (ILO) (2019). *Nasilje i uznemiravanje u svijetu rada: Konvencija br. 190 i Preporuka br. 206.* Ženeva: ILO.

Međunarodna organizacija rada (ILO). (2026). *Prema jednakosti plata.* Ženeva: ILO.

Jann, B. (2008). Blinder-Oaxaca dekompozicija za modele linearne regresije. *The Stata Journal: Promicanje komunikacije o statistici i statistici* , *8* (4), 453-479.

Kovačević, J. i Kapo, A. (2022). Studija o zaposlenosti žena u Bosni i Hercegovini. Sarajevo: RCC.

Lemieux, T. (2006). „Mincerova jednadžba" trideset godina nakon školovanja, iskustva i zarade. U Grossbard, S. (ur.). Jacob Mincer Pionir moderne ekonomije rada. Springer, Boston, MA.

Leythienne, D. i Ronkowski, P. (2018). Dekompozicija neprilagođene rodne razlike u platama korištenjem podataka iz Istraživanja o strukturi zarade. Luksemburg: Ured za publikacije EU-a.

Mincer, J. (1974). Školovanje, iskustvo i zarada. New York: Državni ured za ekonomska istraživanja.

Oaxaca, R. (1973). Razlike u platama između muškaraca i žena na urbanim tržištima rada. International Economic Review 14 (3): 693-709.

Oaxaca, R. (1973). Razlike u platama između muškaraca i žena na urbanim tržištima rada. International Economic Review 14 (3): 693–709.

OECD (2023). *Udruživanje snaga za rodnu ravnopravnost: Šta nas koči?* Pariz: OECD Publishing.

Redmond, P. i McGuinness, S. (2017). Rodna razlika u platama u Europi: preferencije poslova, rodna konvergencija i efekti distribucije. IZA dokument diskusije br. 10933.

Rizvanović, A. i Efendić, A. (2021). Utjecaj obrazovanja na zarade u post-konfliktnoj ekonomiji: dokazi iz Bosne i Hercegovine. Finansial Internet Quarterly 17(2): 1-15.

Shehaj, E. (2022). Regionalni komparativni izvještaj o zaposlenosti žena na Zapadnom Balkanu. Sarajevo: RCC.

STATA. (2011). *Priručnik za Stata bazu – 12.* Teksas: Stata Press.

Centar AIRE i UNDP Bosna i Hercegovina (AIRE i UNDP) (2023). Razotkrivanje nejednakosti na radnom mjestu u Bosni i Hercegovini – Komparativna analiza mehanizama za izvještavanje o rodnim razlikama u platama. Sarajevo: AIRE i UNDP.

UNDP i Agencija za ravnopravnost spolova (2024). Barometar rodne ravnopravnosti u Bosni i Hercegovini. Autori: Spahić, Z. i Đipa, D. (2024). Sarajevo: Program Ujedinjenih naroda za razvoj (UNDP), Agencija za ravnopravnost spolova BiH Ministarstva za ljudska prava i izbjeglice Bosne i Hercegovine.

UNDP i OECD (2025.) . *Kako Europa i Srednja Azija mogu postići rodnu ravnopravnost kroz zelenu tranziciju? Uloga STEM-a i zelenih radnih mjesta.* New York i Pariz: Program Ujedinjenih naroda za razvoj (UNDP) i Organizacija za ekonomsku saradnju i razvoj (OECD).

Izvještaj UNDP-a o ljudskom razvoju za 2025. (UNDP HDR) (2025). Stvar izbora: Ljudi i mogućnosti u doba umjetne inteligencije. New York: UNDP.

Waitkus, N. i Minkus, L. (2021). Istraživanje rodne razlike u bogatstvu među različitim klasama zanimanja. *Feminist Economics* 27 (4): 114-147.

Svjetska banka (2026). Portal za rodne podatke: https://genderdata.worldbank.org/en/indicator/sl-tlf-acti-zs?view=trend&geos=WLD_BIH .

Svjetski ekonomski forum (WEF) (2025.). *Izvještaj o globalnoj rodnoj razlici 2025.* Ženeva: WEF.

DODACI

Dodatak 1. Prilagođeni RRP, metoda Blinder-Oaxaca, puna procjena modela 6

Tabela 9. Prilagođeni RRP, metoda Blinder-Oaxaca, puna procjena modela 6

VARIJABLE		(1) Ukupno	(2) Objašnjeno	(3) Neobjašnjeno
age	Dob		0,00160	-1,454
			(0,0159)	(1,116)
age2	Dob na kvadrat		-0,00481	0,515
			(0,0144)	(0,575)
seceducat	Srednješkolsko obrazovanje		0,103**	0,259*
			(0,0484)	(0,134)
unieduc	Univerzitetsko obrazovanje		-0,177***	0,398*
			(0,0544)	(0,225)
fbih	FBiH prebivalište		0,000118	-0,00848
			(0,00216)	(0,102)
rsbih	RS prebivalište		-0,000113	0,00650
			(0,000819)	(0,0541)
urban	Urbano prebivalište		-0,00182	-0,0277
			(0,00335)	(0,0311)
married	U braku		-0,00238	0,115*
			(0,00234)	(0,0589)
act_politics	Politička aktivnost		0,00376	0,00883
			(0,00272)	(0,0101)
act_ngo	NVO aktivnost		-0,000128	-0,00374
			(0,000566)	(0,0140)
act_human	Aktivnost oko ljudskih prava		-0,000143	-0,000178
			(0,00143)	(0,0154)
act_sport	Sprotska aktivnost		-0,000612	-0,0175
			(0,00378)	(0,0130)
act_lunion	Sindikatska aktivnost		-0,000308	-0,00615
			(0,000800)	(0,0177)
act_inform	Neformalna aktivnost		-0,000921	-0,0160
			(0,00318)	(0,0122)
empl_public	Javni sektor		0,00718	-0,0735
			(0,00614)	(0,0632)

empl_private	Privatni sektor		-0,00460	-0,0575
			(0,00532)	(0,0691)
vulnerable	Ranjivost		0,00403	0,00810
			(0,00368)	(0,0157)
group_1	1. grupa	7,368***		
		(0,0231)		
group_2	2. grupa	7,317***		
		(0,0245)		
difference	Razlika	0,0514		
		(0,0337)		
explained	Objašnjeno	-0,0724***		
		(0,0179)		
unexplained	Neobjašnjeno	0,124***		
		(0,0308)		
Constant				0,478
				(0,723)
Opažanja		917	917	917

Standardna pogreška u zagradama, *** p<0,01, ** p<0,05, * p<0,1

