Prethodno priopćenje
UDK: 316.344:368.914(497.5)
Datum primitka članka u uredništvo: 13. 1. 2026.
Datum slanja članka na recenziju: 3. 2. 2026.
Datum prihvaćanja članka za objavu: 23. 6. 2026.

Tin Štorek, mag. oec. [*]
Dr. sc. Viktor Viljevac [**]

REGIONALNA NEJEDNAKOST MIROVINSKIH PRIMANJA U REPUBLICI HRVATSKOJ

REGIONAL INEQUALITY OF PENSION BENEFITS IN THE REPUBLIC OF CROATIA

SAŽETAK: Ovaj rad donosi prvo istraživanje regionalnih nejednakosti mirovinskih primanja u Republici Hrvatskoj, s naglaskom na promjene u desetogodišnjem razdoblju od prosinca 2014. do prosinca 2024. godine. Analiza je usmjerena na starosne i prijevremene mirovine priznate prema općem propisu. Metodološki pristup temelji se na mjerama nejednakosti koje uključuju decilni omjer, omjer 80/20, Palmin omjer, Ginijev koeficijent, Lorenzovu krivulju i koeficijent varijacije. Rezultati pokazuju da je, uz osjetan nominalni porast mirovinskih primanja, na nacionalnoj razini u promatranih deset godina došlo do blagog smanjenja nejednakosti mjereno svim pokazateljima izuzev Palmina omjera. Viša primanja i dalje su koncentrirana u razvijenijim urbanim područjima, dok pojedine županije istočne i sjeverne Hrvatske zaostaju, što ukazuje na trajne strukturne nejednakosti koje se mogu pripisati razlikama u plaćama i radnome stažu. Rast mirovinskih primanja bio je veći od kumulativne stope inflacije u spomenutom desetogodišnjem razdoblju, stoga je u tom aspektu životni standard prosječnog umirovljenika porastao. To potvrđuje i osjetno smanjenje stope subjektivnog siromaštva.

KLJUČNE RIJEČI: mirovine, nejednakost, Ginijev koeficijent, Lorenzova krivulja, životni standard

JEL KLASIFIKACIJA: D63, H55, I3

ABSTRACT: This paper presents the first study of regional inequalities in pension benefits in the Republic of Croatia, with a focus on changes over a ten-year period from December 2014 to December 2024. The analysis is focused on old-age and early retirement pensions granted under the general statutory scheme. The methodological approach

[*] Tin Štorek, mag. oec., tin.storek07@gmail.com, Odjel za financijsko savjetovanje, Apsolon
[**] Dr. sc. Viktor Viljevac, vviljevac@efzg.hr, Katedra za makroekonomiju i gospodarski razvoj, Ekonomski fakultet – Zagreb

is based on inequality measures including the decile ratio, 80/20 ratio, the Palma ratio, the Gini coefficient, the Lorenz curve, and the coefficient of variation. The results show that, alongside a noticeable nominal increase in pension benefits, there was a slight reduction in inequality at the national level over these ten years, as measured by all indicators except the Palma ratio. Higher benefits remain concentrated in more developed urban areas, while certain counties in eastern and northern Croatia lag behind, indicating persistent structural inequalities that can be attributed to differences in wages and years of service. The growth in pension benefits exceeded the cumulative inflation rate over the mentioned ten-year period; therefore, in this respect, the living standard of the average pensioner increased. This is further confirmed by a significant decline in the rate of subjective poverty.

KEY WORDS: pensions, inequality, Gini coefficient, Lorenz curve, standard of living

JEL CLASSIFICATION: D63, H55, I3

1. UVOD

U raspravama o mirovinskom sustavu u Hrvatskoj naglasak se najčešće stavlja na njegovu dugoročnu održivost u uvjetima nepovoljnih demografskih kretanja. Starenje stanovništva, potencijalno smanjenje broja osiguranika i rast broja umirovljenika ističu se kao glavni izazovi budućeg financiranja mirovina. Međutim, uz fiskalnu održivost sustava, važno je analizirati i raspodjelu mirovinskih primanja među korisnicima. To je dimenzija o kojoj se u javnim raspravama govori znatno manje, iako ona uvelike određuje životni standard i socijalnu sigurnost starijeg stanovništva.

Mirovine su za veliki dio građana glavni, a često i jedini izvor dohotka u starijoj dobi. Razlike u visini mirovinskih primanja stoga neposredno utječu na rizik od siromaštva, a time i kvalitetu života umirovljenika. Nejednakost mirovina odražava obrasce sudjelovanja na tržištu rada – visinu i stabilnost plaća, duljinu radnog staža i kontinuitet zaposlenja – pa se može promatrati i kao rezultat dugoročnih ekonomskih i socijalnih procesa. Ako je ta nejednakost izražena, ona ne utječe samo na pojedince nego i na cjelokupno društvo jer produbljuje ekonomske razlike među generacijama i regijama.

Zbog toga se u ovom radu, koji donosi prvi prikaz mjera nejednakosti regionalnih mirovinskih primanja unutar hrvatskog mirovinskog sustava, analizira kretanje nejednakosti mirovinskih primanja u razdoblju od prosinca 2014. do prosinca 2024. godine, odnosno ispituje se dolazi li u navedenom razdoblju do njezina smanjenja. Ova su dva mjeseca odabrana zbog toga što 2014. godina predstavlja dno višegodišnje recesije, nakon čega slijedi relativno uspješno razdoblje gospodarskog rasta, uz izuzetak recesije povezane s pandemijom bolesti COVID-19. Posebna se pozornost usmjerava i na regionalne razlike kako bi se istražilo postoje li među županijama značajne razlike u visini mirovinskih primanja. Tako se dobiva šira slika o socijalnoj i ekonomskoj ulozi mirovinskog sustava u Republici Hrvatskoj. U radu se analizira i promjena životnog standarda umirovljenika u spomenutom desetogodišnjem razdoblju.

Rad je podijeljen na pet poglavlja, uključujući prvo, uvodno. U drugom se poglavlju daje pregled međunarodne i domaće literature vezane uz različite vrste nejednakosti i njihove uzroke i posljedice. U trećem se poglavlju opisuju korišteni podaci i metodologija.

Četvrto poglavlje donosi rezultate i raspravu o rezultatima, a u petom se poglavlju daje zaključak rada.

2. EKONOMSKE I DRUŠTVENE IMPLIKACIJE NEJEDNAKOSTI

Nejednakost u društvu odnosi se na neujednačenu raspodjelu resursa, mogućnosti i životnih ishoda među pojedincima i skupinama. Ona se može manifestirati u različitim oblicima, od ekonomskih razlika u prihodima i bogatstvu, do društvenih nejednakosti poput pristupa obrazovanju, zdravstvu i drugim javnim dobrima. Ekonomska nejednakost, koja se najčešće mjeri distribucijom dohotka ili bogatstva, usko je povezana s društvenom kohezijom, gospodarskim rastom i političkom stabilnošću (Stiglitz, 2012.). Uzroci nejednakosti višestruki su. Na globalnoj razini uključuju čimbenike kao što su razlike u pristupu kapitalu i tehnološkom razvoju, dok unutar pojedinih zemalja važnu ulogu imaju porezni sustav, radno zakonodavstvo i obuhvat socijalnih politika (Atkinson, 2015.). Posebno u starijoj životnoj dobi, glavni izvor dohotka za većinu građana jest mirovina. Nejednakost u visini mirovina odražava kumulativne učinke nejednakosti tijekom radnog vijeka. Budući da visina mirovine proizlazi iz iznosa plaća, duljine staža i uplaćenih doprinosa, razlike na tržištu rada prenose se i u razlike u mirovinskim primanjima (Whitehouse, 2007).

U okviru mirovinskog sustava, nejednakost se ogleda u razlici između pojedinačnih iznosa mirovina i raspodjele tih iznosa među korisnicima. Minimalne mirovine djeluju redistributivno, smanjujući razlike između najnižih i prosječnih primanja, dok visoke mirovine, osobito one ostvarene iznadprosječnim plaćama, povećavaju ukupnu disperziju iznosa mirovina (Polo Andrés i Viejo Rubio, 2011). Na razini sustava, prosječna mirovina, jednako kao i prosječna plaća, skriva veliku unutarnju disperziju. Rizik dohodovnog siromaštva među starijim osobama (65+) u državama članicama Europske unije (EU-27), mjeren udjelom osoba s ekvivalentnim raspoloživim dohotkom ispod 60 % nacionalnog medijana, smanjivao se do 2016. godine, nakon čega ponovno bilježi porast. Dodatno, rodne razlike u plaćama i duljini staža rezultiraju trajnim rodnim jazom u mirovinama, čime se produbljuju postojeće socijalne nejednakosti (European Commission, 2021). Žene tijekom radnog vijeka češće ostvaruju niže plaće, imaju kraće i fragmentiranije karijere te su izloženije prekidima zaposlenja, osobito zbog skrbi za djecu i druge članove obitelji, što se izravno odražava na nižu razinu akumuliranih mirovinskih prava. Empirijska istraživanja pritom pokazuju da takvi obrasci rezultiraju sustavno nižim mirovinama i manjim mirovinskim bogatstvom žena u odnosu na muškarce (Cordova, Grabka i Sierminska, 2022). Rodni jaz ne predstavlja samo individualnu razliku, već važnu strukturnu komponentu ukupne nejednakosti u raspodjeli mirovinskih primanja (Abatemarco, Lagomarsino i Russolillo, 2023), pri čemu dostupne analize upućuju na njegovu postojanost čak i unatoč institucionalnim prilagodbama mirovinskih sustava (Deschacht, Guillemyn i Vujic, 2025).

Suvremena empirijska literatura naglašava da se nejednakost mirovinskih primanja formira tijekom cijelog životnog ciklusa pojedinaca, pri čemu razlike u plaćama, kontinuitetu zaposlenja i uplatama doprinosa predstavljaju ključne determinante konačne raspodjele mirovina (Valdés-Prieto i Leyton, 2025). Osobe s višim i stabilnijim dohocima akumuliraju veća mirovinska prava, dok prekidi u zaposlenju, niže plaće i nesigurni oblici rada rezulti-

raju trajno nižim mirovinama. Istodobno, istraživanja pokazuju da standardne mjere nejednakosti podcjenjuju njezin stvarni opseg jer ne uzimaju u obzir razlike u životnom vijeku, s obzirom na to da osobe višeg socioekonomskog statusa dulje žive i dulje primaju mirovine, čime se ukupna nejednakost dodatno povećava (Shi i Kolk, 2022; Shi i Kolk, 2023). Na razini Europe, raspodjela mirovinskog bogatstva potvrđuje ove obrasce, jer je snažno koncentrirana i usko povezana s ukupnom raspodjelom dohotka i imovine (Olivera, 2019).

Implikacije nejednakosti u mirovinskom sustavu očituju se u povećanom riziku relativnog siromaštva i materijalne oskudice među starijim osobama, dok podaci OECD-a istodobno upućuju na to da su starije osobe s nižim prihodima i one koje žive same izloženije slabijoj društvenoj povezanosti, smanjenom sudjelovanju u društvenim aktivnostima i većem riziku od socijalne izolacije (OECD, 2015; OECD, 2024). Dugotrajno siromaštvo u starijoj dobi također ima međugeneracijske učinke, budući da članovi obitelji često moraju preuzeti dio troškova skrbi, što povećava financijski pritisak na radno aktivno stanovništvo (European Commission, 2021). Implikacije nejednakosti u mirovinskom sustavu stoga nisu samo pojedinačne, već društvene i ekonomske prirode, one produbljuju socijalne razlike i smanjuju ukupnu razinu društvene kohezije.

Više autora analiziralo je različite aspekte nejednakosti u Republici Hrvatskoj. Kroflin i Mačkić (2021) ističu da je Ginijev koeficijent nejednakosti dohotka 2018. godine u Republici Hrvatskoj iznosio 0,304, tek zanemarivo više od prosjeka europodručja (0,302). Ukupno je 13 zemalja Europske unije imalo veći Ginijev koeficijent od Hrvatske te isto toliko manji. Ginijev koeficijent nejednakosti neto imovine bio je osjetno veći (0,606), ali i dalje ispod prosjeka zemalja europodručja (0,70). Autori zaključuju da podaci ne ukazuju na visoke razine nejednakosti u Hrvatskoj u odnosu na većinu razvijenih zemalja, pogotovo ne u odnosu na globalne ekstreme kao što je SAD. S druge strane, autori ističu da Hrvatska bilježi veće razine nejednakosti u odnosu na neke slične postsocijalističke zemlje kao što su Slovenija i Slovačka te porast visine Ginijeva koeficijenta nejednakosti dohotka od 1988. do 2018. godine. Što se tiče regionalnih nejednakosti, Doolan i Tonković (2021) navode podatke Državnog zavoda za statistiku, prema kojima je stopa rizika od siromaštva u 2019. godini u Jadranskoj Hrvatskoj bila 16,1 %, a u Kontinentalnoj Hrvatskoj ta je stopa iznosila 19,4 %.

Nguyen i Rubil (2021) analizirali su kako fiskalna politika utječe na nejednakost i siromaštvo u Republici Hrvatskoj. Zaključuju kako je 2018. godine fiskalni sustav pridonio smanjenju nejednakosti, ali je istodobno povećao siromaštvo. Sve fiskalne mjere izuzev neizravnih poreza, odnosno PDV-a i trošarina, smanjile su nejednakost. S druge strane, neizravni porezi povećali su i nejednakost i doveli do porasta siromaštva. Izravni porezi nisu imali utjecaj na siromaštvo u 2018. godini, dok su ga izravni transferi smanjivali. Navode i kako je niz reformi uveden između 2018. i 2021. godine blago smanjio siromaštvo, prvenstveno zbog smanjenja PDV-a na neke prehrambene proizvode. Za analizu toga kako fiskalna politika (posebno progresivnost poreza) utječe na nejednakost i društveno blagostanje u Republici Hrvatskoj vidjeti Ledić, Rubil i Urban (2022).

Kunovac (2020) analizira podatke za 2016. godinu iz Ankete o financijama i potrošnji kućanstava, fokusirajući se na distribuciju imovine kućanstava. Njezina analiza pokazuje da je 85 % kućanstava posjedovalo glavnu stambenu jedinicu, osjetno više u usporedbi s prosjekom Europske unije, a pripadajući Ginijev koeficijent iznosio je 0,56. S druge strane, nejednakost kod raspodjele financijske imovine bila je osjetno veća, pri čemu je tek 5 % kućanstava izjavilo da posjeduje dionice te 0,4 % obveznice. Kunovac poziva na oprez kod

tumačenja podataka za financijsku imovinu s obzirom na to da su vrijednosti prijavljene u Anketi oko sedam puta manje od onih u financijskim računima. Zanimljivo, postotak anketiranih umirovljenika koji se nalazio u najnižoj kvintilnoj skupini prema vrijednosti neto imovine (bruto imovina umanjena za obveze) bio je manji od istovjetnog postotka za kategoriju zaposlenih, dok je postotak umirovljenika koji se nalazio u najvišoj kvintilnoj skupini bio nešto veći od postotka za kategoriju zaposlenih. Drugim riječima, unatoč relativno niskom iznosu prosječne mirovine u odnosu na prosječnu plaću u Republici Hrvatskoj, umirovljenička populacija ne stoji podjednako loše u odnosu na zaposlene kada je u pitanju neto imovina, što je logično s obzirom na dulji vijek mogućnosti akumuliranja neto imovine. Kunovac (2020) ističe i regionalne nejednakosti, pri čemu se kao najsiromašnija izdvajaju općinska naselja u Istočnoj Hrvatskoj, dok su kućanstva u Primorju i gradu Zagrebu u prosjeku imućnija, odnosno imaju veću vrijednost neto imovine.

3. PODACI I METODOLOGIJA

U ovom poglavlju definiraju se podaci koji se koriste u analizi, kao i metode korištene za analizu nejednakosti – decilni omjer, omjer 80/20, Palmin omjer, Ginijev koeficijent i Lorenzova krivulja.

3.1. Korišteni podaci

U empirijskoj analizi upotrijebljeni su sekundarni podaci prikupljeni na mjesečnoj razini za prosinac 2014. i prosinac 2024. godine. Podaci su dobiveni izravno od Hrvatskog zavoda za mirovinsko osiguranje, iz njihove baze podataka i nisu dostupni javno. Podaci koji se koriste u empirijskoj analizi su neto isplaćene mirovine po županijama i spolu. U analizu su uključene isključivo mirovine koje su bile u redovnoj isplati u promatranim mjesecima, a odnose se na korisnike s prebivalištem ili boravištem u Republici Hrvatskoj. Obuhvaćene su starosne i prijevremene mirovine priznate prema općem propisu, dok su sve ostale vrste i prava mirovina u potpunosti isključeni iz analize. Pod ostalim pravima i vrstama mirovina smatraju se invalidske mirovine, obiteljske mirovine, inozemne mirovine i mirovine prema posebnim propisima. Ovakav odabir podataka omogućava dosljednu usporedbu temeljnog sustava mirovinskog osiguranja i izbjegava odstupanja koja bi mogla proizaći zbog drugih vrsta mirovina i posebnih prava reguliranih izvan općeg propisa.

U prosincu 2014. godine tako je analizirano 499.274 isplaćenih mirovina, što čini približno 45,7 % od ukupno 1.091.663 (HZMO, 2015) isplata za navedeni mjesec. Za prosinac 2024. godine broj analiziranih isplaćenih mirovina iznosio je 554.403, odnosno približno 52,5 % od ukupnih 1.056.482 (HZMO, 2025) isplaćenih mirovina za navedeni mjesec. Detaljna raspodjela broja opažanja po županijama prikazana je u Prilogu 1. Ukupan broj mirovina u oba promatrana razdoblja odnosi se isključivo na isplate unutar Republike Hrvatske, pri čemu su sve isplate u inozemstvo isključene.

3.2. Metodologija

3.2.1. Decilni omjer i Palmin omjer

Decilna distribucija predstavlja metodu razdiobe podataka, u ovom slučaju mirovinskih primanja, na deset jednakih dijelova, pri čemu se populacija rangira prema određenom kriteriju, u ovom slučaju prema visini mirovine. Svaki decil obuhvaća 10 % populacije, raspoređenih od najnižih (prvi decil) do najviših (deseti decil) mirovina (OECD, 2008). Primjerice, prvi decil predstavlja iznos u odnosu na koji 10 % umirovljenika prima manju ili jednaku mirovinu, a preostalih 90 % umirovljenika veću ili jednaku mirovinu.

Na temelju vrijednosti decila izračunava se i niz pokazatelja nejednakosti. Jedan od njih je omjer između devetog i prvog decila:

$$\boldsymbol{Decilni\ omjer} = \frac{\boldsymbol{D^9}}{\boldsymbol{D^1}}$$

koji mjeri koliko je puta dohodak na granici devetog decila veći od onoga na granici prvog decila (Eurostat, 2025a). Sve češće se koristi i Palmin omjer koji uspoređuje koncentraciju dohotka između 10 % najviših i 40 % najnižih dohodaka. Izračunava se kao:

$$\boldsymbol{Palmin\ omjer} = \frac{\boldsymbol{u_{10}}}{\boldsymbol{u_1 + u_2 + u_3 + u_4}}$$

Pri čemu, primjerice, u_1 predstavlja udio u ukupnom dohotku (zbroju svih mirovina) koji ostvaruje 10 % populacije s najnižim dohocima. Nazivnik stoga predstavlja udio koji 40 % umirovljenika s najnižim mirovinama ima u ukupnoj masi (zbroju) mirovina, a brojnik udio koji ima 10 % umirovljenika s najvišim iznosima mirovina. Palmin omjer temelji se na empirijskom opažanju da srednjih 50 % stanovništva u većini društava ostvaruje relativno stabilan udio u dohotku, pa se razlike među zemljama uglavnom koncentriraju na krajevima distribucije (Cobham i Sumner, 2013). Slično se može definirati i omjer 80/20:

$$\boldsymbol{Omjer\ 80/20} = \frac{\boldsymbol{u_{10} + u_9}}{\boldsymbol{u_1 + u_2}}$$

On mjeri koliko je puta dohodak 20 % populacije s najvišim dohotkom veći u odnosu na dohodak 20 % populacije s najnižim dohotkom.

3.2.2. Lorenzova krivulja i Ginijev koeficijent

Lorenzova krivulja koristi se za prikaz raspodjele dohotka ili bogatstva u nekom društvu. Lorenz (1905) uvodi koncept kako bi ilustrirao koncentraciju bogatstva među stanovništvom SAD-a. Kako navodi Cowell (2011), Lorenzovu krivulju možemo matematički prikazati na dolje prikazani način.

Neka se raspodjela dohotka promatra među *n* pojedinaca ili kućanstava, čiji su dohoci

$$\boldsymbol{x_1, x_2, \ldots, x_n}$$

pri čemu vrijedi $x_1 \leq x_2 \leq \cdots \leq x_n$. Ukupni dohodak može se zapisati kao $T = \sum_{i=1}^{n} x_i$, a srednji dohodak s $\mu = \frac{T}{n}$..

Lorenzova krivulja prikazuje kumulativni udio ukupnog dohotka koji ostvaruju pojedini udjeli stanovništva, počevši od onih s nižim primanjima. U kontekstu ovog rada, primjena krivulje odnosi se na raspodjelu mirovinskih primanja. Za svako

$i \in \{1, ..., n\}$, definira se:

Kumulativni udio stanovništva:

$$p_i = \frac{i}{n}$$

i kumulativni udio dohotka:

$$L(p_i) = \frac{\sum_{j=1}^{i} x_j}{T}$$

Lorenzova je krivulja u diskretnom slučaju skup točaka $(p_i, L(p_i))$, uključujući početnu točku **(0,0)**. U kontinuiranom slučaju, kada je raspodjela opisana funkcijom gustoće $F(x)$ s distribucijskom funkcijom $F(x)$, krivulja se definira kao

$$L(p) = \frac{1}{\mu} \int_0^{F^{-1}(p)} x f(x)\, dx$$

Gdje je $F^{-1}(p)$ kvantilna funkcija, a $\mu = \int_0^{\infty} x f(x)\, dx$ očekivani dohodak.

Za sve $p \in [0, 1]$ vrijedi:

$L(0) = 0$

$L(1) = 1$

$L(p) \leq p$

$L(p)$ je rastuća i konveksna

Lorenzova krivulja uvijek se nalazi ispod dijagonale, osim u slučaju savršene jednakosti, kada vrijedi $L(p) = p$ za svaki p. Ginijev koeficijent računa se tako da se površina između dijagonale i Lorenzove krivulje podijeli s ukupnom površinom ispod dijagonale. Njegova vrijednost kreće se od nula, što je hipotetski slučaj u kojem svi pojedinci imaju jednak dohodak, do jedan, što predstavlja hipotetski slučaj u kojem jedna osoba dobiva sav dohodak, a ostali ništa (Gregory i Stuart, 2014).

Grafikon 1. Hipotetski primjer Lorenzove krivulje



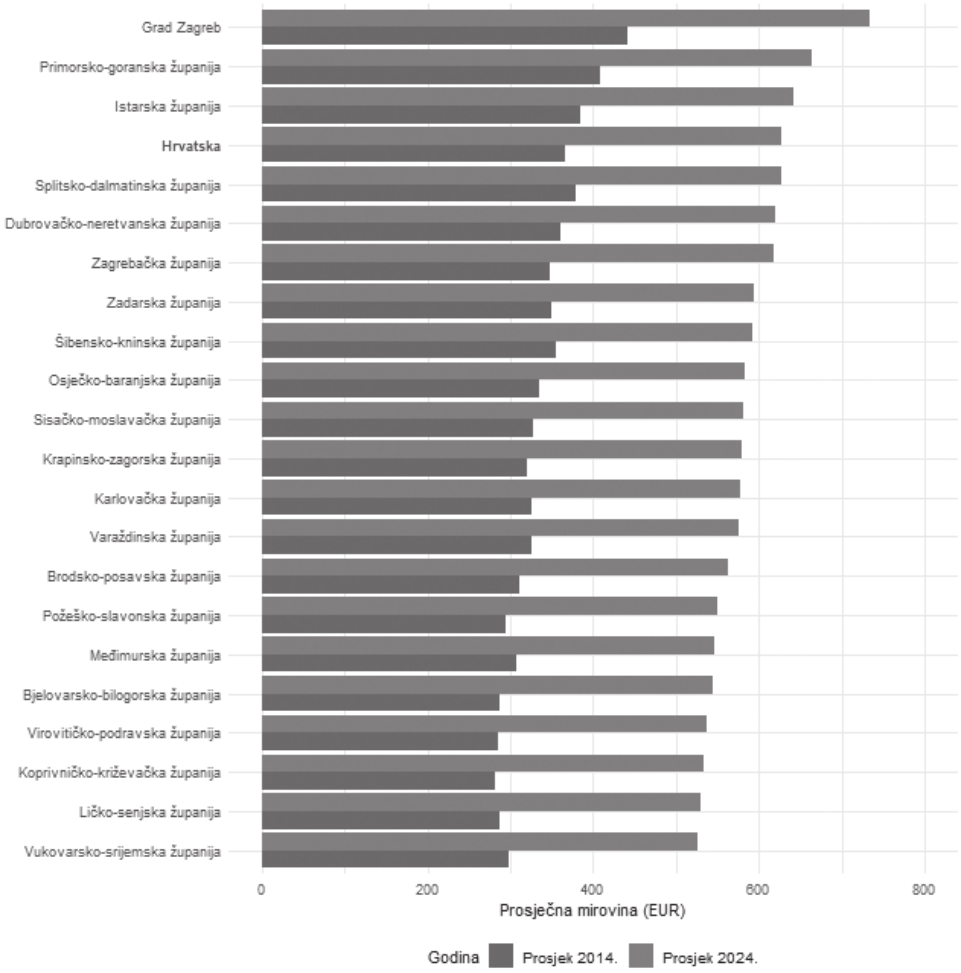
Izvor: izrada autora

Uz navedene mjere, prikazat će se kretanje prosječne i medijalne mirovine kako bi se analiziralo kretanje životnog standarda umirovljenika te kretanje vrijednosti koeficijenta varijacije kao jednog od pokazatelja nejednakosti.

4. EMPIRIJSKI REZULTATI

Kako bi se analiziralo regionalno kretanje nejednakosti od prosinca 2014. do prosinca 2024. godine, u ovom poglavlju prikazano je kretanje prosječne i medijalne mirovine, koeficijenta varijacije, decilnog omjera, omjera 80/20 i Palmina omjera te Ginijeva koeficijenta i Lorenzove krivulje za 21 županiju i Republiku Hrvatsku. Mjere nejednakosti se prvo prikazuju i komentiraju deskriptivno, a potom se na kraju poglavlja daje komentar koji povezuje rezultate dobivene s pomoću različitih mjera.

Grafikon 2. Prosječna mirovina po županijama za prosinac 2014. i prosinac 2024. godine



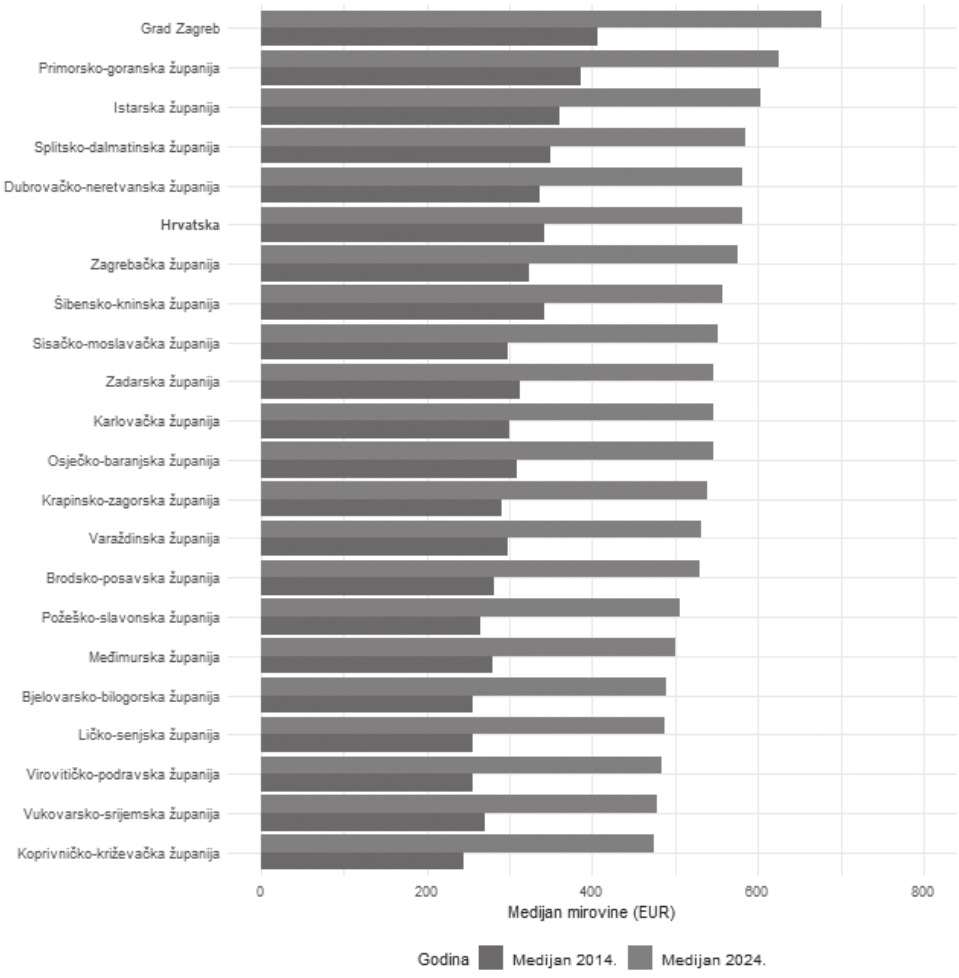
Izvor: izračun autora na temelju podataka Hrvatskog zavoda za mirovinsko osiguranje

Grafikon 2. prikazuje prosječne iznose mirovina po županijama u prosincu 2014. i prosincu 2024. godine. U razdoblju od deset godina prosječna mirovina u Hrvatskoj porasla je s 366,80 EUR na 627,54 EUR, što predstavlja rast od 71,1 %. U apsolutnim iznosima, najveći rast zabilježen je u Gradu Zagrebu, gdje je prosječna mirovina porasla za čak 291,7 EUR, dok je u Zagrebačkoj županiji porast bio 270,2 EUR, Dubrovačko-neretvanskoj županiji 258,9 EUR, a u Krapinsko-zagorskoj županiji 257,8 EUR. Najmanji apsolutni porast prosječnih mirovina ostvaren je u Vukovarsko-srijemskoj županiji (227,8 EUR), Šibensko-kninskoj županiji (236,9 EUR), Ličko-senjskoj županiji (242,4 EUR) i Zadarskoj županiji (243,1 EUR).

Tri županije s najvišim stopama rasta bile su Koprivničko-križevačka (89,6 %), Bjelovarsko-bilogorska (89,0 %) i Virovitičko-podravska (88,0 %), dok su tri županije koje

su zabilježile najmanje postotno povećanje Primorsko-goranska (62,1 %), Splitsko-dalmatinska (65,2 %) i Grad Zagreb (66,1 %). Iako su sve županije zabilježile osjetno postotno povećanje, prisutne su izražene regionalne razlike u visini mirovina. U prosincu 2024. godine najviše prosječne mirovine ostvaruju korisnici u Gradu Zagrebu (733,30 EUR), dok su znatno iznad državnog prosjeka još i Primorsko-goranska županija (662,82 EUR) te Istarska županija (640,99 EUR). S druge strane, najniže prosječne mirovine zabilježene su u Vukovarsko-srijemskoj (525,08 EUR), Ličko-senjskoj (529,62 EUR), Virovitičko-podravskoj (537,55 EUR) i Bjelovarsko-bilogorskoj županiji (543,78 EUR), koje sve zaostaju više od 15 % u odnosu na državni prosjek.

Grafikon 3. Medijalna mirovina po županijama za prosinac 2014. i prosinac 2024. godine



Izvor: izračun autora na temelju podataka Hrvatskog zavoda za mirovinsko osiguranje

Grafikon 3. prikazuje medijalne iznose mirovina po županijama za prosinac 2014. i prosinac 2024. godine. Na razini Republike Hrvatske, medijalna mirovina porasla je s 341,71 EUR na 580,18 EUR, što predstavlja porast od oko 69,8 % (prosječna mirovina porasla je 71,1 %). Na razini svih županija koeficijent korelacije između stopa rasta prosječne i stopa rasta medijalne mirovine iznosi 0,964, a županije su zabilježile slične stope rasta medijalne i prosječne mirovine. Najveća postotna razlika u stopama rasta zabilježena je u Brodsko-posavskoj i Sisačko-moslavačkoj županiji, gdje je stopa rasta medijalne mirovine bila oko 10 % veća od stope rasta prosječne mirovine. Poredak županija prema medijalnoj mirovini ne razlikuje se mnogo od poretka prema prosječnoj mirovini.

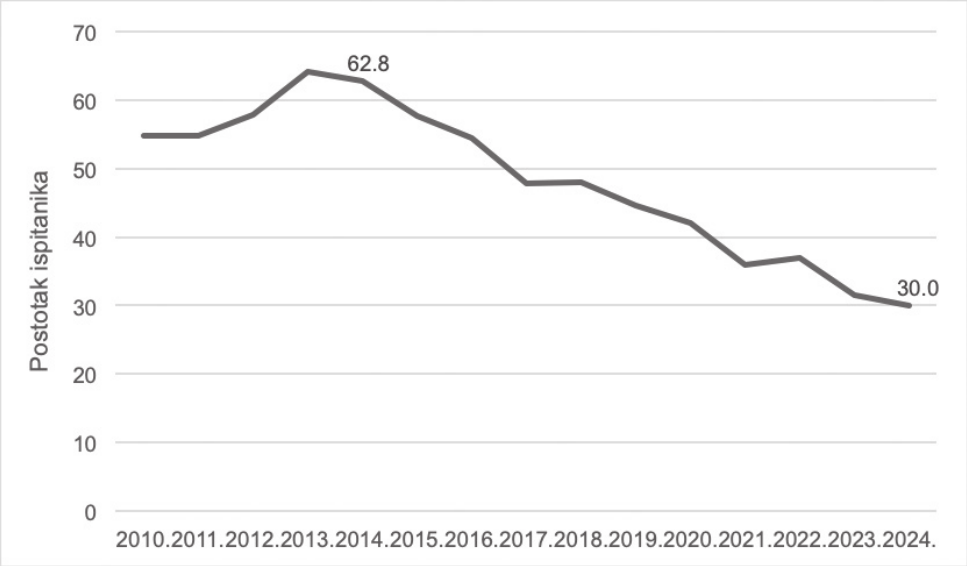
Ako govorimo o promjeni životnog standarda umirovljenika u ovom desetogodišnjem razdoblju, mjereno indeksom potrošačkih cijena, cijene su u prosjeku kumulativno porasle 32,06 %. U istom razdoblju cijene u kategoriji „Hrana" zabilježile su osjetno veću prosječnu stopu rasta u iznosu od 50,66 % (DZS, 2025). Ipak, kako je medijalna mirovina na razini Republike Hrvatske u tom razdoblju porasla 69,8 % (prosječna 71,1 %), može se zaključiti da je životni standard umirovljenika porastao. Ovaj zaključak vrijedi i kada se uzme u obzir da ne trpe sve dohodovne skupine jednaku inflaciju. Istraživanje Rubila, Tkalec i Žilića (2024) pokazalo je da skupine građana s nižim dohocima trpe više stope inflacije od one „opće", koju objavljuje Državni zavod za statistiku. No, ta razlika nije dovoljno velika da promijeni ovaj zaključak. Primjerice, ako se na temelju podataka iz Ankete o potrošnji kućanstava u 2022. (DZS, 2024) na temelju strukture izdataka potrošnje konstruira stopa inflacije za prvi decil[1], kumulativna stopa inflacije za taj decil je od prosinca 2014. do prosinca 2024. godine iznosila 32,79 %, tek malo više od prethodno spomenute opće stope inflacije od 32,06 %. Pri tome je bitno napomenuti da svaki umirovljenik ima vlastitu inflaciju, koja ovisi o specifičnoj potrošačkoj košarici koju ta osoba kupuje te stoga neminovno postoje umirovljenici čija je stopa inflacije bila veća od ovdje navedenih postotaka.

Zaključak da su mirovine rasle više od cijena vrijedi za sve županije – primjerice, Primorsko-goranska županija zabilježila je najnižu stopu rasta medijalne mirovine (62,0 %), ali je ta stopa osjetno veća od kumulativne stope inflacije te veća od rasta cijena u kategoriji „Hrana". Nadalje, u prosincu 2014. godine aktualna vrijednost mirovine iznosila je 8,09 eura, a u prosincu 2024. godine 13,17 eura, stoga su radi redovitog usklađivanja za rast plaća i cijena mirovine u tom razdoblju povećane 62,9 %. Ta je stopa bila veća i od inflacije mjerene indeksom potrošačkih cijena i od rasta cijena u kategoriji „Hrana". Drugim riječima, ne može se zaključiti da stope rasta prosječne i medijalne mirovine prikrivaju velik postotak umirovljenika čije mirovine u tom razdoblju nisu pratile rast cijena. Kao dodatan argument za tvrdnju o porastu životnog standarda umirovljenika mogu poslužiti podaci o subjektivnom siromaštvu iz Ankete o dohotku stanovništva koju provodi Državni zavod za statistiku. Subjektivno siromašnima smatraju se oni ispitanici koji su na pitanje vezano uz

[1] Ovaj izračun temelji se na podacima o strukturi izdataka za potrošnju različitih decilnih skupina. Primjerice, podaci iz spomenute Ankete pokazuju da je udio kategorije „Hrana i bezalkoholna pića" u ukupnoj potrošnji prvog decila 2022. godine iznosio 35,8 %, osjetno više od udjela od 25,2 % za deveti decil. Prvi decil uključuje 10 % kućanstava koja imaju najniže godišnje izdatke. Na temelju ovih udjela može se konstruirati prilagođena potrošačka košarica za prvi decil, koja umjesto pondera od 27,0 % za kategoriju „Hrana i bezalkoholna pića", što predstavlja udio te kategorije u ukupnim izdacima svih anketiranih kućanstava zajedno, koristi pondere za prvi decil. Ponderi za prvi decil se potom množe s indeksima cijena u različitim kategorijama izdataka kako bi se izračunala prilagođena inflacija za prvi decil. Za više detalja vidjeti Rubil, Tkalec i Žilić (2024)

to uz kolike poteškoće spajaju kraj s krajem odgovorili „vrlo teško“ ili „teško“, što su dva najnepovoljnija odgovora. Na sljedećem je grafikonu prikazan postotak subjektivno siromašnih ispitanika u kategoriji 65+.

Grafikon 4. Postotak subjektivno siromašnih građana u Republici Hrvatskoj, 65+

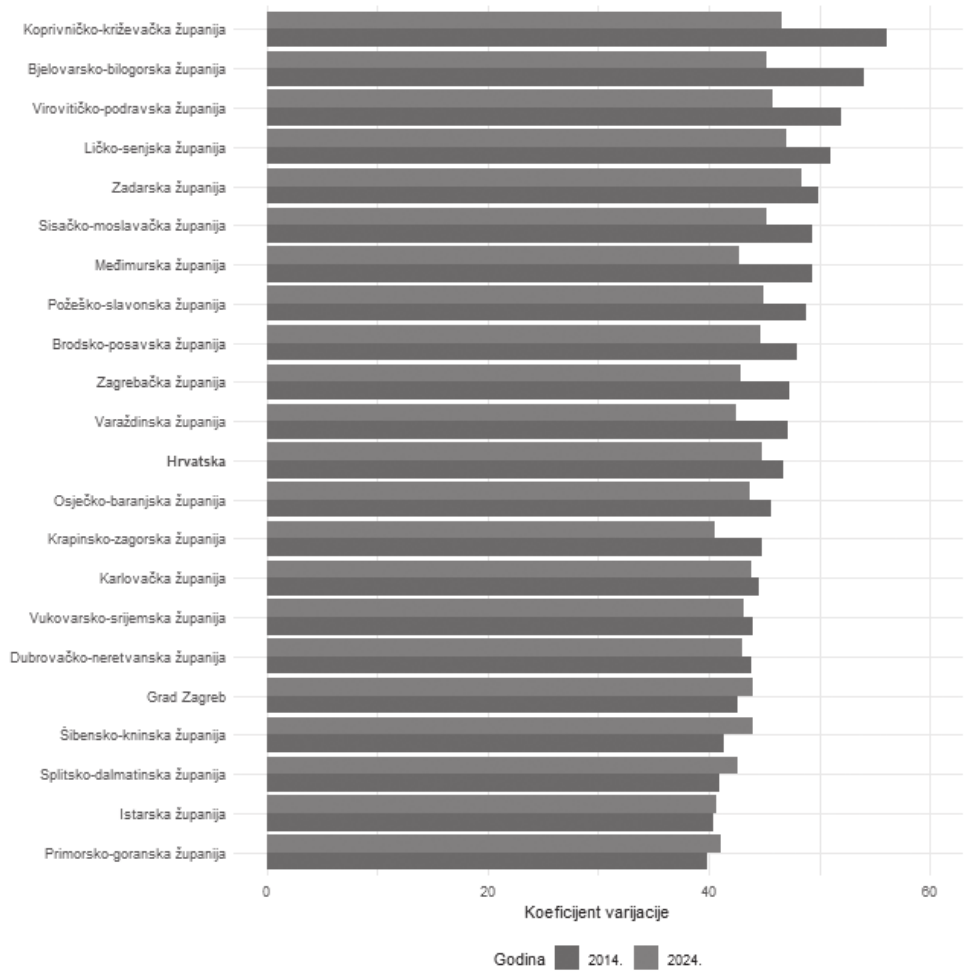


Izvor: Eurostat (2025b)

Na grafikonu se vidi da je postotak ispitanika starijih od 64 godine koji se kategoriziraju kao subjektivno siromašni više nego prepolovljen od 2014. do 2024. godine, što je u skladu sa zaključkom da su prosječna i medijalna mirovina rasle po osjetno većoj stopi od kumulativne inflacije. To pak ne znači da se stopu od 30 % iz 2024. godine može smatrati niskom ni u apsolutnom ni u relativnom smislu – istovjetna stopa je na razini EU-27 te godine iznosila 14,9 % (Eurostat, 2025b). Također, bitno je napomenuti da umirovljenička populacija u prosincu 2014. godine nije istovjetna umirovljeničkoj populaciji iz prosinca 2024. godine, odnosno da su se u tih deset godina dogodili i priljevi i odljevi iz te populacije.

Iako se rijetko koristi u tu svrhu za razliku od indikatora koji slijede u nastavku, nastavno na prikazane prosječne vrijednosti mirovina može se analizirati kretanje koeficijenta varijacije, koji se definira kao omjer standardne devijacije i prosječne vrijednosti. Smanjenje koeficijenta varijacije tumači se kao pad relativne disperzije (raspršenosti) mirovina u odnosu na prosječnu mirovinu, i obrnuto.

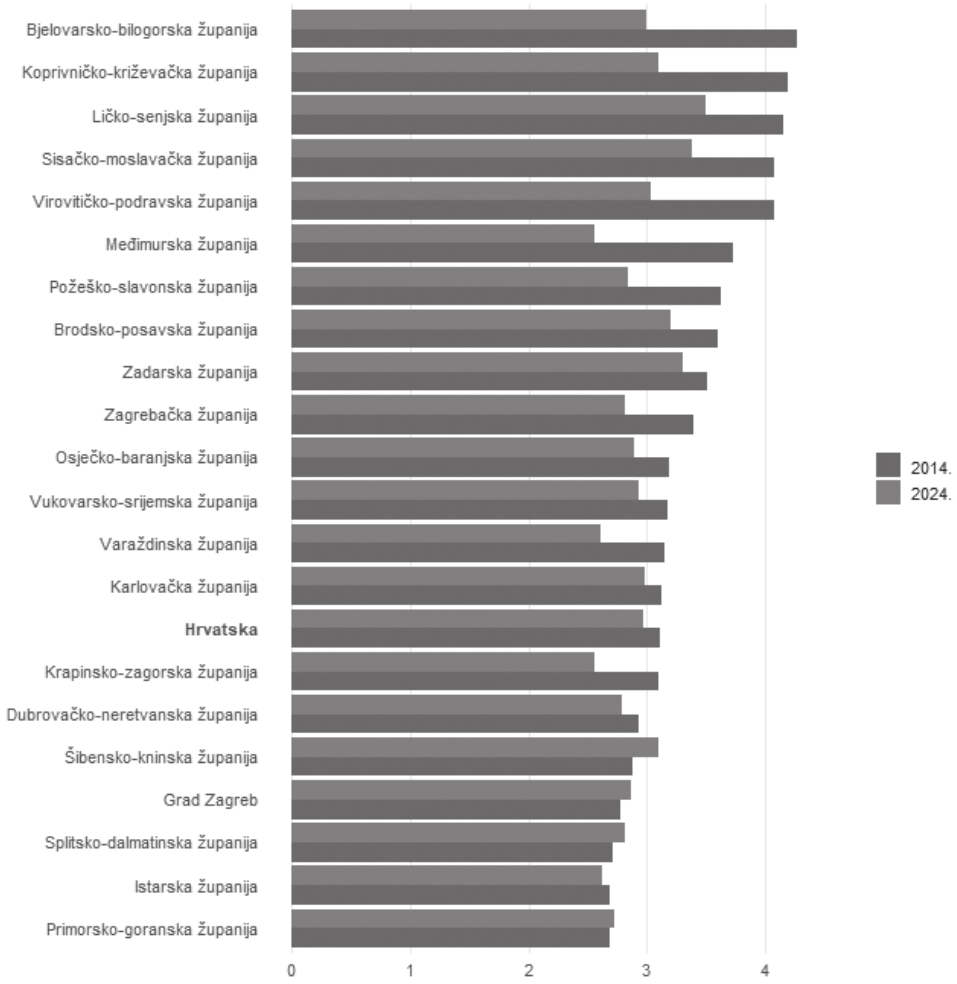
Grafikon 5. Koeficijent varijacije mirovina po županijama u prosincu 2014. i prosincu 2024. godine



Izvor: izračun autora na temelju podataka Hrvatskog zavoda za mirovinsko osiguranje

Na grafikonu se vidi da je na razini Republike Hrvatske došlo do blagog smanjenja koeficijenta varijacije u prosincu 2024. u odnosu na prosinac 2014. godine, odnosno da je prema tom pokazatelju nejednakost pala. Koeficijent varijacije smanjio se u 16, a povećao u pet županija. Na sljedećem je grafikonu prikazano kretanje decilnog omjera.

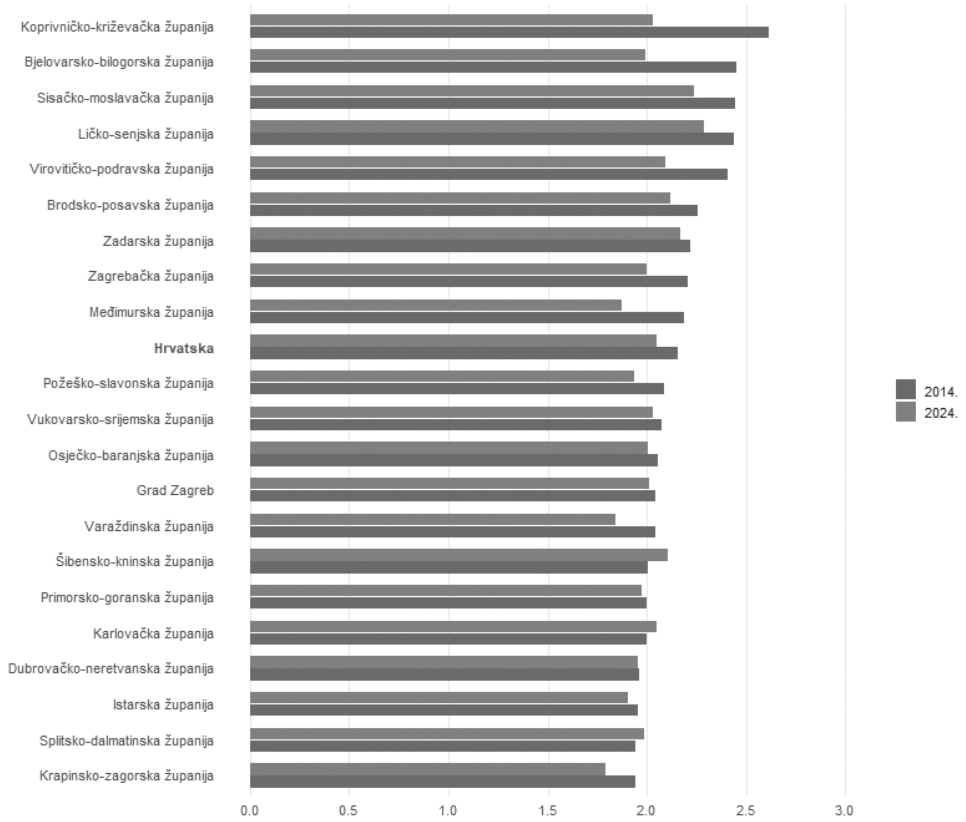
Grafikon 6. Decilni omjer mirovinskih primanja po županijama za prosinac 2014. i prosinac 2024. godine



Izvor: izrada autora na temelju podataka Hrvatskog zavoda za mirovinsko osiguranje

Decilni omjer (omjer 90/10) mjeri koliko je puta deveti decil mirovina veći od prvog decila mirovina. Kao i kod koeficijenta varijacije, i kod decilnog omjera došlo je do blagog smanjenja na razini Republike Hrvatske. Decilni omjer smanjio se u 17, a povećao u četiri županije. Na sljedećem je grafikonu prikazano kretanje omjera 80/20.

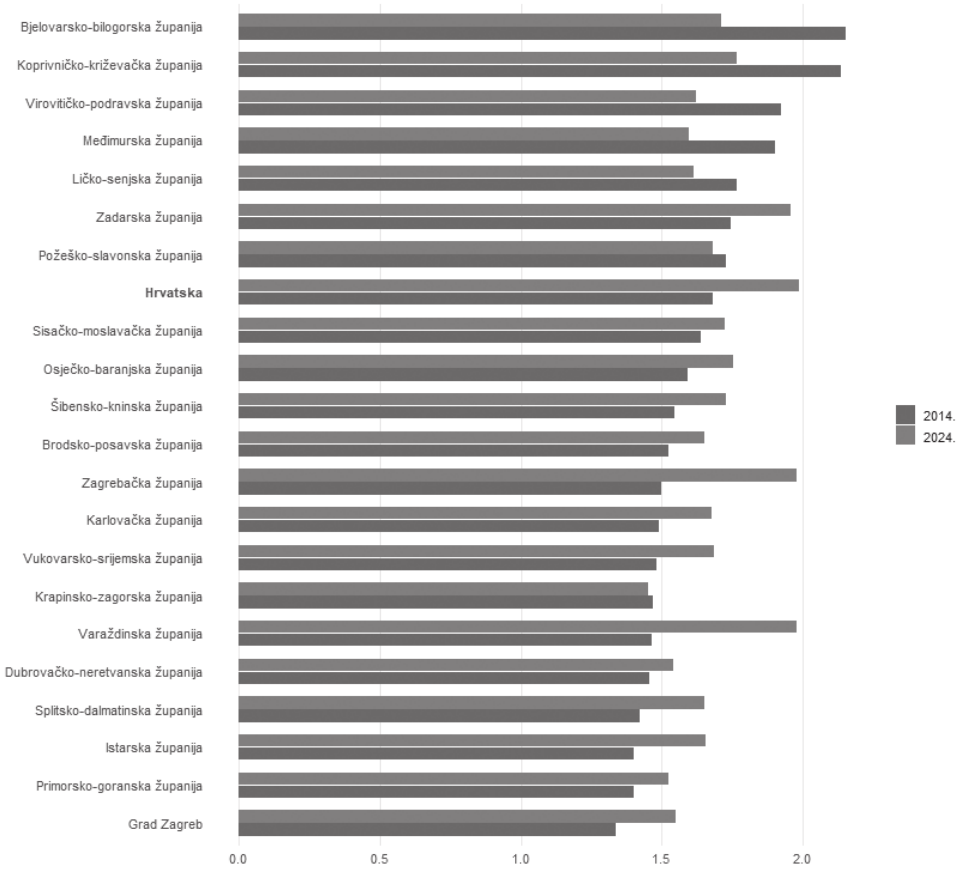
Grafikon 7. Omjer 80/20 mirovinskih primanja po županijama za prosinac 2014. i prosinac 2024. godine



Izvor: izrada autora na temelju podataka Hrvatskog zavoda za mirovinsko osiguranje

Omjer 80/20 mjeri odnos između ukupnih mirovina koje prima 20 % umirovljenika s najvišom mirovinom i 20 % umirovljenika s najnižom mirovinom. Odnosno, pokazuje koliko su mirovinska primanja koncentrirana kod onih s najvišim mirovinama u odnosu na one s najnižima. Grafikon prikazuje blago smanjenje nejednakosti između 2014. i 2024. godine. U većini županija zabilježen je pad vrijednosti pokazatelja, što upućuje na ujednačavanje raspodjele mirovina. Najizraženije smanjenje vidljivo je u Koprivničko-križevačkoj i Bjelovarsko-bilogorskoj županiji, dok su pojedine županije, poput Šibensko-kninske i Karlovačke, zabilježile blagi rast. Na razini Hrvatske također je prisutan pad omjera.

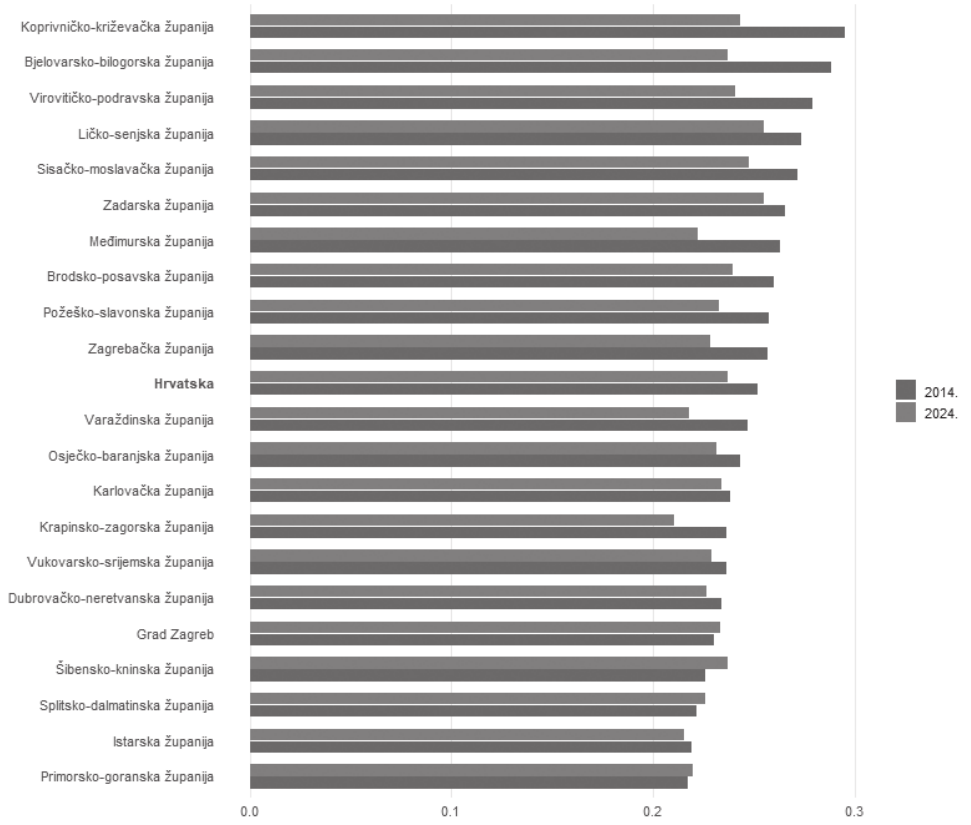
Grafikon 8. Palmin omjer mirovinskih primanja po županijama za prosinac 2014. i prosinac 2024. godine



Izvor: izračun autora na temelju podataka Hrvatskog zavoda za mirovinsko osiguranje

Na razini Republike Hrvatske, vrijednost Palmina omjera porasla je s 1,68 u prosincu 2014. godine na 1,99 u prosincu 2024. godine, što ukazuje na povećanje koncentracije mirovinskih primanja kod najviših skupina umirovljenika u odnosu na donje skupine. Drugim riječima, u prosincu 2024. godine je masa mirovina 10 % umirovljenika s najvišim mirovinama bila 1,99 puta veća u odnosu na masu mirovina 40 % umirovljenika s najnižim mirovinama. Iako je na nacionalnoj razini zabilježeno povećanje nejednakosti, trendovi se razlikuju među županijama. Palmin omjer povećao se u 14, a smanjio u sedam županija. Na Grafikonu 9. prikazane su vrijednosti Ginijeva koeficijenta.

Grafikon 9. Ginijev koeficijent mirovinskih primanja po županijama za prosinac 2014. i prosinac 2024. godine



Izvor: izrada autora na temelju podataka Hrvatskog zavoda za mirovinsko osiguranje

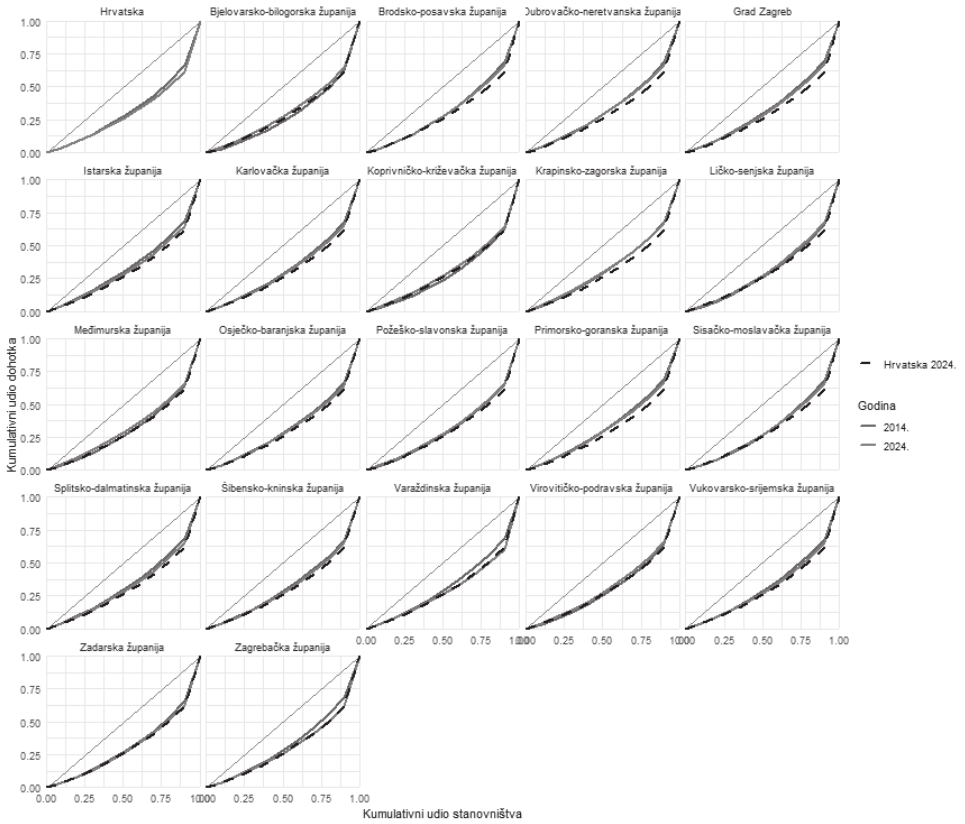
Na nacionalnoj razini, Ginijev koeficijent smanjio se s 0,252 u prosincu 2014. godine na 0,237 u prosincu 2024. godine, što ukazuje na blago smanjenje relativne nejednakosti u raspodjeli mirovina. Na regionalnoj razini je smanjenje koeficijenta zabilježeno u 17, a povećanje u četiri županije. Najveće smanjenje nejednakosti zabilježeno je u županijama s nižim razinama mirovinskih primanja, poput Koprivničko-križevačke (s 0,296 na 0,243), Bjelovarsko-bilogorske (s 0,289 na 0,237) i Međimurske županije (s 0,263 na 0,222).

Nastavno na dosad prikazane rezultate, na razini Republike Hrvatske sve mjere nejednakosti izuzev Palmina omjera pokazuju pad. Nejednakost mirovinskih primanja na razini države smanjena je mjereno koeficijentom varijacije, decilnim omjerom, omjerom 80/20 i Ginijevim koeficijentom, a porasla mjereno Palminim omjerom. Drugim riječima, masa 10 % najviših mirovina rasla je po većoj stopi od mase 40 % najnižih mirovina usprkos tome što je, primjerice, deveti decil rastao po manjoj stopi od prvoga pa je decilni omjer smanjen i usprkos tome što je omjer 80/20 blago smanjen. Odnosno, masa 10 % najviših mirovina zabilježila je relativno visoku stopu rasta. Stoga se može zaključiti da je došlo do određenog porasta nejednakosti ako se masa 10 % najviših mirovina usporedi s najdonjih 40 % mirovina, ali je nejednakost smanjena mjereno drugim mjerama.

Nadalje, najveće smanjenje nejednakosti (mjereno svim mjerama, uključujući Palmin omjer) zabilježeno je u županijama kao što su Bjelovarsko-bilogorska, Koprivničko-križevačka, Virovitičko-podravska i Ličko-senjska. To su ujedno županije koje su imale najniže početne (prosinac 2014. godine) iznose prosječne i medijalne mirovine, te je također u tim županijama zabilježen najveći postotni porast prosječne i medijalne mirovine (grafikoni 2. i 3.). Drugim riječima, najveći pad nejednakosti zabilježen je u županijama s relativno niskim medijalnim i prosječnim mirovinama u prosincu 2014. godine, što znači da su u tim županijama niže plaće rasle po većim stopama od onih viših. Jedno moguće objašnjenje ovakvih kretanja jest promjena strukture umirovljenika. Moguće je da je kod priljeva novih umirovljenika u tom razdoblju bila riječ o umirovljenicima koji su radili osjetno drugačije poslove od postojećih umirovljenika, od kojih su mnogi primali relativno niske poljoprivredne mirovine. Također, došlo je i do odljeva upravo tih starijih umirovljenika s relativno niskim mirovinama. S obzirom na to da ne raspolažemo detaljnijim podacima o vrsti poslova koje su ti umirovljenici obavljali, ovo otvara prostor za daljnja istraživanja ovih promjena.

Posljednja mjera nejednakosti analizirana u ovom radu su Lorenzove krivulje, kojima se vizualno prikazuje raspodjela mirovinskih primanja i razina njihove nejednakosti. Lorenzove krivulje prikazane su na Grafikonu 10.

Grafikon 10. Lorenzove krivulje mirovinskih primanja po županijama za prosinac 2014. i prosinac 2024. godine



Izvor: izrada autora na temelju podataka Hrvatskog zavoda za mirovinskog osiguranje

Može se uočiti da u analiziranom razdoblju nije došlo do velikih promjena u pogledu nejednakosti – u skladu s blagim smanjenjem Ginijeva koeficijenta na nacionalnoj razini, Lorenzova krivulja za Republiku Hrvatsku blago se pomaknula prema dijagonali. I krivulje određenih županija za prosinac 2024. godine blago se približavaju dijagonali u odnosu na prosinac 2014. godine, što ukazuje na određeno smanjenje relativne nejednakosti u raspodjeli mirovinskih primanja. Ovakav trend izražen je u županijama poput Koprivničko-križevačke, Međimurske, Virovitičko-podravske i Bjelovarsko-bilogorske županije, gdje se distribucija mirovina postupno mijenja te se smanjuje jaz između donjih i gornjih skupina umirovljenika. Nasuprot tome, u županijama poput Splitsko-dalmatinske županije, Šibensko-kninske županije, Primorsko-goranske županije i Grada Zagreba, Lorenzove krivulje pokazuju vrlo blagi rast nejednakosti, odnosno udaljavanje od dijagonale savršene jednakosti. Ovi rezultati potvrđuju da su, unatoč značajnom rastu mirovina na nacionalnoj razini, regionalne razlike i dalje prisutne te da nisu sve županije zabilježile smanjenje relativne nejednakosti. Ujednačenija raspodjela mirovinskih primanja zabilježena je uglavnom u županijama s nižim mirovinama, dok razvijenije sredine pokazuju tendenciju širenja apsolutnih razlika.

U međunarodnom kontekstu, na razini OECD-a nejednakost mjerena Ginijevim koeficijentom među starijima (65+) se od 2000. do 2022. godine u prosjeku nije značajno mijenjala, no kretanja po pojedinim zemljama nisu jednoznačna te u nekim slučajevima dolazi do smanjenja nejednakosti (primjerice, Portugal, Grčka i Slovačka), dok u drugima dolazi do njezina povećanja (primjerice, Novi Zeland, Švedska i Danska) (OECD, 2025).

5. ZAKLJUČAK

Ovaj rad ima tri glavna zaključka. Prvo, na razini Republike Hrvatske četiri korištene mjere nejednakosti pokazuju blago smanjenje nejednakosti distribucije mirovina, a jedna njezin porast. Koeficijent varijacije, decilni omjer, omjer 80/20 i Ginijev koeficijent zabilježili su blago smanjenje od prosinca 2014. do prosinca 2024. godine. S druge strane, Palmin omjer je u ovom razdoblju zabilježio povećanje, stoga rezultat o blagom smanjenju nejednakosti nije jednoznačan. Drugo, nejednakost se različito kretala na razini županija. Primjerice, županije kao što su Koprivničko-križevačka, Bjelovarsko-bilogorska i Virovitičko-podravska zabilježile su smanjenje nejednakosti prema svih pet spomenutih mjera. S druge strane, županije kao što su Splitsko-dalmatinska i Šibensko-kninska zabilježile su porast nejednakosti mjereno svim korištenim mjerama. Treće, i prosječne i medijalne mirovine u svim su županijama rasle po osjetno većoj stopi od kumulativne stope inflacije, iz čega proizlazi da je životni standard prosječnog i medijalnog umirovljenika u ovom razdoblju porastao. Radi redovitog usklađivanja za rast plaća i cijena mirovine su u tom razdoblju povećane 62,9 %, a kumulativna inflacija u tom razdoblju iznosila je 32,06 %. Prosječan rast cijena u kategoriji „Hrana“ iznosio je osjetno većih 50,66 %, ali je to manje od spomenutih stopa rasta mirovina. Ovom zaključku ide u prilog i osjetno smanjenje stope subjektivnog siromaštva građana starijih od 64 godine.

LITERATURA

1. Abatemarco, A., Lagomarsino, F. i Russolillo, D. (2023) Pension inequality and its determinants. *Social Indicators Research*, *167*(2).
2. Atkinson, A. B. (2015). *Inequality: What can be done?* Harvard University Press.
3. Cobham, A. i Sumner, A. (2013) *Is it all about the tails? The Palma measure of income inequality* (Working Paper 343.) Center for Global Development.
4. Cordova, K., Grabka, M. M. i Sierminska, E. (2022) Gender differences in pension wealth. *Journal of Pension Economics and Finance*, *21*(3).
5. Cowell, F.A. (2011.) *Measuring inequality* (3rd ed.). Oxford University Press.
6. Deschacht, N., Guillemyn, A. i Vujic, S. (2025) Gender inequality in occupational pensions. *European Journal of Social Security*, *27*(1).
7. Doolan, K. i Tonković, Ž. (2021). Što nam klasna analiza govori o nejednakostima u hrvatskom društvu? U *(Ne)jednakosti u Hrvatskoj: Uvidi u problematiku nejednakosti u hrvatskom društvu povodom 25. obljetnice Zaklade Friedrich Ebert Zagreb.*
8. Državni zavod za statistiku (2024). *Životni uvjeti, dohodak i socijalna isključenost. Rezultati Ankete o potrošnji kućanstava u 2022*. Dostupno na: https://podaci.dzs.hr/hr/podaci/zivotni-uvjeti-dohodak-i-socijalna-iskljucenost/ (pristupano 4. 1. 2026.)
9. Državni zavod za statistiku (2025). *PC-Axis baze podataka. Cijene*. Dostupno na: https://web.dzs.hr/PXWeb/Menu.aspx?px_language=hr&px_type=PX&px_db=Cijene (pristupano 18. 12. 2025.)
10. European Commission (2021) *Pension adequacy report 2021: Current and future income adequacy in old age in the EU*. Publications Office of the European Union.
11. Eurostat (2025a). *Earnings statistics*. Dostupno na: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Earnings_statistics
12. Eurostat (2025b). *Subjective poverty by sex and age*. Dostupno na: https://ec.europa.eu/eurostat/databrowser/view/ilc_sbjp01__custom_19619852/default/table (pristupano 18. 12. 2025.)
13. Gregory, P. R. i Stuart, R. C. (2014). *The global economy and its economic systems*. South-Western Cengage Learning.
14. Hrvatski zavod za mirovinsko osiguranje (HZMO) (2015) *Statističke informacije Hrvatskog zavoda za mirovinsko osiguranje, broj 4/2014, veljača 2015*. Dostupno na: https://www.mirovinsko.hr/hr/2014/1304
15. Hrvatski zavod za mirovinsko osiguranje (HZMO) (2025) *Statističke informacije Hrvatskog zavoda za mirovinsko osiguranje, broj 12/2024, siječanj 2025*. Dostupno na: https://www.mirovinsko.hr/hr/2024-3377/3377
16. Kroflin, M. i Mačkić, V. (2021). Ekonomske nejednakosti u Republici Hrvatskoj – što znamo o njima i kako ih ublažiti? U *(Ne)jednakosti u Hrvatskoj: Uvidi u problematiku nejednakosti u hrvatskom društvu povodom 25. obljetnice Zaklade Friedrich Ebert Zagreb.*
17. Kunovac, M. (2020). *Distribucija imovine kućanstava u Hrvatskoj* (Istraživanja I-57). Hrvatska narodna banka. Dostupno na: https://www.hnb.hr/documents/20182/3063386/i-057.pdf/e310a99b-3db5-ab2a-4952-50c8d28b6217

18. Kunovac M. (2020). Distribution of household assets in Croatia. *Public Sector Economics*, *44*(3), str. 265 – 297.
19. Ledić, M., Rubil, I. i Urban, I. (2022). Tax progressivity and social welfare with a continuum of inequality views. *International Tax and Public Finance, 30*, 1266–1296 (2023). https://doi.org/10.1007/s10797-022-09752-y
20. Lorenz, M.O. (1905) Methods of measuring the concentration of wealth. *Publications of the American Statistical Association, 9*(70), 209–219.
21. Nguyen, N.T.V. i Rubil, I. (2021). Fiscal Policies, Inequality, and Poverty in Croatia. *Radni materijali EIZ-a*, (4), 3-62. Preuzeto s https://hrcak.srce.hr/263208
22. OECD (2008.). *OECD Glossary of Statistical Terms*. OECD Publishing. https://doi.org/10.1787/9789264055087-en
23. OECD (2015). *Pensions at a Glance 2015: OECD and G20 indicators*. OECD Publishing. https://doi.org/10.1787/pension_glance-2015-en.
24. OECD (2024). *Addressing Inequality in Budgeting: Lessons from Recent Country Experience*. OECD Publishing. https://doi.org/10.1787/ea80d61d-en.
25. OECD (2025). *Pensions at a Glance 2025: OECD and G20 Indicators*. OECD Publishing. https://doi.org/10.1787/e40274c1-en
26. Olivera, J. (2019) The distribution of pension wealth in Europe. *The Journal of the Economics of Ageing*, *13*, 30-42.
27. Polo Andrés, F. i Viejo Rubio, M. (2011) Minimum pensions and regional income redistribution in Spain. *Hacienda Pública Española/Review of Public Economics*, *197*(2), 9–44.
28. Rubil, I., Tkalec, M. i Žilić, I. (2024). Nejednakosti inflacije u Hrvatskoj. *Revija za socijalnu politiku, 31*(1), 1-27. https://doi.org/10.3935/rsp.v31i1.1965
29. Shi, J. i Kolk, M. (2022). How does mortality contribute to lifetime pension inequality? Evidence from five decades of Swedish taxation data. *Demography*, *59*(5), 1843-1871.
30. Shi, J. i Kolk, M. (2023). The inequality of lifetime pensions. *Sociological Science*, *7*, 667-693.
31. Stiglitz, J.E. (2012) *The price of inequality: How today's divided society endangers our future*. W.W. Norton & Company.
32. Valdés-Prieto, S. i Leyton, S. (2025) Inequality in pension contribution gaps. *Labour Economics*, *97*.
33. Whitehouse, E. R. (2007) *Pensions panorama: Retirement-income systems in 53 countries*. World Bank.

PRILOG 1.

Broj opažanja po županijama i za Republiku Hrvatsku, prosinac 2014. i 2024. godine

Županija	**prosinac 2014.**	**prosinac 2024.**
Bjelovarsko-bilogorska županija	13.137	14.216
Brodsko-posavska županija	13.172	13.953
Dubrovačko-neretvanska županija	15.005	16.402
Grad Zagreb	110.594	119.576
Istarska županija	30.336	36.971
Karlovačka županija	16.868	16.339
Koprivničko-križevačka županija	14.319	15.116
Krapinsko-zagorska županija	12.569	15.017
Ličko-senjska županija	5.743	5.189
Međimurska županija	10.251	13.170
Osječko-baranjska županija	31.296	33.022
Požeško-slavonska županija	6.795	7.115
Primorsko-goranska županija	45.833	51.812
Sisačko-moslavačka županija	18.534	19.116
Splitsko-dalmatinska županija	45.654	54.688
Šibensko-kninska županija	12.356	13.054
Varaždinska županija	18.607	22.368
Virovitičko-podravska županija	7.744	7.909
Vukovarsko-srijemska županija	17.484	17.476
Zadarska županija	19.379	21.505
Zagrebačka županija	33.598	40.389
Hrvatska	499.274	554.403

Izvor: izrada autora na temelju podataka Hrvatskog zavoda za mirovinskog osiguranje