Marina Tkalec [a]

JEL klasifikacija: E31, D31, D12, C23
Izvorni znanstveni rad
https://doi.org/10.32910/ep.77.5.1

Nejednakost inflacije i njezine strukturne determinante: Analiza na razini mikropodataka

Sažetak

Rad analizira odrednice nejednakosti inflacije u Hrvatskoj (2019.–2025.) koristeći mikropodatke iz Ankete o potrošnji kućanstava. Regresijskom analizom objedinjenih ponovljenih poprečnih presjeka i LASSO metodom identificirane su socioekonomske karakteristike koje predviđaju izloženost porastu cijena. Upravo se razina dohotka u našoj analizi nameće kao faktor koji presudno diktira kako se inflacijski teret raspoređuje među građanima. Takva izrazita izloženost skupina s nižim primanjima zapravo je izravna posljedica strukturne neelastičnosti njihove potrošnje, budući da im u košarici dominiraju egzistencijalne stavke poput hrane i energenata koje je nemoguće jednostavno supstituirati. Promatrajući isključivo najniži dohodovni decil, pokazalo se da su samci i kućanstva s većim brojem članova u znatno nepovoljnijem položaju, dok se utjecaj dobi, iako prisutan, očituje u znatno manjoj mjeri. Primjenom LASSO algoritma identificirana je i korelacija između fizičke imovine i stope inflacije, čime su navike potrošača i njihovo imovinsko stanje postali jasni prediktori osjetljivosti na cjenovne šokove. Dok posjedovanje automobila ili zamrzivača pojačava ranjivost na cjenovne šokove energenata, faktori poput višeg standarda stanovanja i korištenja klima-uređaja paradoksalno djeluju kao zaštitni mehanizmi protiv inflatornih pritisaka. Rad zaključuje da mjere zaštite od inflacije trebaju biti progresivne i usmjerene na specifične demografske skupine i energetski osjetljiva kućanstva.

Ključne riječi: nejednakost inflacije, inflacija kućanstava, Hrvatska, heterogenost potrošnje, LASSO regresija.

---

[a] M. Tkalec, dr.sc., znanstvena savjetnica, Ekonomski institut, Zagreb (e-mail: mtkalec@eizg.hr). Autorica za korespondenciju. Rad je primljen u uredništvo 04.02.2026. godine, a prihvaćen je za objavu 16.04.2026. godine.

1. UVOD

Snažan porast opće razine cijena koji je započeo sredinom 2021. godine vratio je inflaciju u središte akademskih i političkih rasprava. Iako je indeks potrošačkih cijena (IPC) ključna statistika ekonomske politike, za dublje razumijevanje ekonomskih procesa nužno je razlikovati sam fenomen inflacije od njegova statističkog prikaza. Inflacija nipošto nije uniforman proces, već višedimenzionalna pojava koja pogađa društvene skupine na krajnje različite načine. Formulacija ekonomskih politika može biti posve pogrešna ako se oslanja isključivo na agregirane mjere, čime se zanemaruje kompleksnost i heterogenost fenomena o kojoj govore Rubil, Tkalec i Žilić (2024).

Nakon vrhunca od 13,5 posto u studenom 2022., inflacija u Hrvatskoj bilježi postupno usporavanje, no zadržava se sustavno iznad prosjeka europodručja i tijekom 2024. i 2025. godine. Taj inflacijski višak, potaknut prvenstveno cijenama hrane i usluga, dodatno produbljuje jaz u kupovnoj moći različitih skupina kućanstava unutar same zemlje. Kontekst dvoznamenkastih trendova i njihovih posljedica na distribuciju bogatstva ne može se promatrati odvojeno od ulaska Hrvatske u europodručje početkom 2023. godine. Iako inicijalni nalazi (Falagiarda, Gartner, Mužić i Pufnik, 2023) sugeriraju da sama konverzija nije bila primarni pokretač općeg rasta cijena, trenutak uvođenja eura, usred globalnog inflacijskog vala, učinio je razlike u stvarnoj izloženosti kućanstava bolno vidljivima. Falagiarda i sur. (2023) pritom posebno apostrofiraju sektor usluga kao kritičnu točku u kojoj su se percepcija građana i stvarni cjenovni izazovi najjače sudarili s općom dinamikom inflacije.

Motivacija ovog rada proizlazi iz potrebe za odmakom od isključivo agregatnih mjera prema analizi inflacije na razini kućanstva. Iako je literatura o nejednakosti inflacije u porastu, i dalje postoji značajan jaz u razumijevanju konkretnih odrednica (determinanti) tih nejednakosti. Ovaj rad predstavlja izravan nastavak istraživanja Rubil i sur. (2024), koji su analizirali nejednakosti inflacije u Hrvatskoj za razdoblje 2001. – 2021. koristeći 12 glavnih kategorija potrošnje ili COICOP (engl. *Classification of Individual Consumption According to Purpose*). Dok su se prethodna istraživanja primarno fokusirala na izračun same nejednakosti, ovaj rad ide korak dalje analizirajući socioekonomske karakteristike kućanstava koje tu nejednakost generiraju.

Relevantna literatura naglašava da upotreba skalarne mjere za opisivanje multidimenzionalnog fenomena, poput inflacije, može prikriti značajne varijacije u individualnim iskustvima porasta cijena. Kako ističu Kaplan i Schülhofer-Wohl (2017), prosječna potrošačka košarica često ne reprezentira niti jedno stvarno kućanstvo, a varijacije u stopama inflacije po kućanstvima primarno proizlaze iz razlika u plaćenim cijenama i sastavu košarica. Razumijevanje ovih razlika ključno je jer različite mjere istog fenomena impliciraju bitno drukčije poglede na svijet, ekonomske politike i zaključke o pravednosti distribucije inflacijskog tereta.

Glavni doprinos ovog rada očituje se u tri smjera. Prvo, koristimo najnovije dostupne podatke iz Ankete o potrošnji kućanstava (APK) za 2022. godinu, što omogućuje uvid u promjene u strukturama potrošnje nakon pandemije i tijekom energetskog šoka. Drugo, analiziramo seriju ponovljenih poprečnih presjeka (engl. *repeated cross-sections*) za razdoblje od 2019. do 2025. godine, čime obuhvaćamo različite ekonomske epizode, od niske inflacije do dvoznamenkastih stopa rasta cijena. Konstrukcijom individualnih stopa inflacije na mjesečnoj razini podaci se transformiraju u format pogodan za analizu distribucijskih učinaka kroz vrijeme, čime se simulira pseudo-panel pristup koji omogućuje identifikaciju dugoročnih strukturnih determinanti. Treće, uz standardnu regresijsku analizu, primjenjujemo metodu strojnog učenja (LASSO regresiju) kako bismo identificirali najprediktivnije karakteristike kućanstava za izloženost inflaciji, uključujući posjedovanje trajne imovine i životne stilove.

Glavni cilj ovoga rada jest identificirati i kvantificirati ključne odrednice heterogenosti inflacije na razini kućanstava u Republici Hrvatskoj u razdoblju od 2019. do 2025. godine. Istraživanje teži utvrditi u kojoj mjeri varijacije u individualnim stopama inflacije proizlaze iz razlika u razini dohotka, demografskoj strukturi kućanstava te posjedovanju specifične trajne imovine — poput automobila i uređaja za hlađenje ili zamr-

zavanje — koja uvjetuje energetsku osjetljivost potrošačke košarice.

U skladu s postavljenim ciljem, rad nastoji odgovoriti na sljedeća istraživačka pitanja: Postoji li sustavan jaz u stopama inflacije između kućanstava različitih dohodovnih decila te kako se taj jaz mijenjao tijekom ekstremnih cjenovnih šokova u 2022. i 2023. godini? Koji socioekonomski i imovinski faktori najsnažnije predviđaju izloženost kućanstva inflaciji kada se kontroliraju demografske karakteristike? U kojoj mjeri službeni indeks potrošačkih cijena podcjenjuje stvarni inflacijski teret niskodohodovnih kućanstava?

Ostatak rada strukturiran je na sljedeći način. Nakon uvoda slijedi pregled relevantne domaće i međunarodne literature o nejednakosti inflacije. Treće poglavlje detaljno opisuje korištene izvore podataka te daje metodološki okvir s posebnim naglaskom na izračun inflacije po kućanstvima i specifikaciju ekonometrijskih modela. Četvrto poglavlje donosi glavne empirijske rezultate, uključujući nalaze regresijske analize objedinjenih podataka i LASSO selekciju varijabli. U petom, zaključnom poglavlju, raspravljaju se implikacije rezultata za ekonomske politike, iznose se zaključna razmatranja te nude smjernice za buduća istraživanja.

2. PREGLED LITERATURE

2.1. Teorijski okvir i mjerenje inflacije na razini kućanstva

Potreba za mjerenjem inflacije na razini kućanstva nije novijeg datuma; još je Jevons (1874) isticao da bi se, zbog različitog sastava potrošnje, inflacija trebala mjeriti individualno. Ipak, u službenim statistikama prevladava indeks potrošačkih cijena koji, kao skalarna mjera, često ne predstavlja niti jedno konkretno kućanstvo. Suvremena literatura naglašava važnost razlikovanja samog fenomena inflacije od njezine mjere (indeksa), budući da različite mjere mogu dovesti do bitno drukčijih zaključaka o blagostanju i distribucijskim učincima.

Kaplan i Schülhofer-Wohl (2017) koriste skener podatke kako bi izračunali distribuciju inflacije na razini kućanstva u SAD-u te utvrđuju značajne varijacije koje proizlaze iz različitih cijena plaćenih za iste proizvode, ali i sastava košarice unutar kategorija. U europskom kontekstu, Gürer i Weichenrieder (2020) pokazuju da je košarica 10 posto kućanstava s najnižim dohotkom u EU postala u prosjeku značajno skuplja od košarice kućanstava s najvišim dohotkom. Za Hrvatsku, temelje su postavili Rubil i sur. (2024) analizirajući razdoblje 2001. – 2021., dokumentirajući postojanje inflacijskih nejednakosti kroz duži vremenski period.

2.2. Determinante nejednakosti inflacije

Dohodak je ključna odrednica inflacijske nejednakosti. Dok Jaravel (2021) ističe da kućanstva s višim dohotkom profitiraju od tržišnih inovacija, fenomen „cheapflation" (Chen, Levell i O'Connell, 2024; IFS, 2024) pokazuje da cijene bazičnih varijanti proizvoda rastu znatno brže od „premium" inačica, što je zorno potvrđeno na primjeru rasta cijena najjeftinijih namirnica u Ujedinjenom Kraljevstvu. Ovakva dinamika generira visoku nejednakost koju službene statistike, temeljene na agregatnim kategorijama, često podcjenjuju (Cavallo i Kryvtsov, 2024).

Osim dohotka, na inflacijsku nejednakost značajno utječe i demografska struktura, primarno dob kućanstva. Hipoteza o starijim kućanstvima koja, raspolažući s više slobodnog vremena, amortiziraju inflaciju kroz potragu za popustima (Aguiar i Hurst, 2007), u recentnim se kriznim uvjetima čini sve manje održivom. Naime, snažni inflatorni pritisci iz razdoblja 2021.–2023. stubokom mijenjaju tu dinamiku. Podaci koje iznose Chen i sur. (2024) sugeriraju da dob u takvim ekstremnim okolnostima prestaje biti prednost te se, paradoksalno, pretvara u značajan faktor rizika za kućanstva. Ako je potrošnja fokusirana na energente i hranu, manevarski prostor za uštede kroz potragu za akcijskim cijenama postaje zanemariv u usporedbi s općim rastom cijena tih nužnih dobara.

Uz lokaciju stanovanja (Handbury, 2021), dostupnost e-trgovine trajno oblikuje inflacijsku nejednakost jer omogućuje lakšu usporedbu cijena i pristup povoljnijim kanalima nabave izvan lokalnog tržišta. Međutim, te su prednosti asi-

metrično raspoređene zbog digitalnog jaza (Cavallo, 2017), što niskodohodovnim kućanstvima ograničava mogućnost izbjegavanja lokalnih cjenovnih šokova, ostavljajući ih ovisnima o fizičkim trgovinama s višim maržama. Dodatni izazov predstavlja metodološki jaz nastao tijekom pandemije; Cavallo (2024) dokazuje da su službene statistike, zbog tromosti u prilagodbi pondera stvarnim promjenama u potrošačkim navikama, sustavno podcijenile troškove života u krizi.

2.3. Životni stil i energetska osjetljivost

Novija istraživanja sve više pažnje posvećuju utjecaju strukture imovine i specifičnih obrazaca potrošnje na inflacijsku dinamiku. U tom kontekstu, Wehrhöfer (2023) ističe kako energetska poskupljenja ne oblikuju samo inflacijska očekivanja, već generiraju i vrlo opipljiv pritisak na kućne budžete. Umjesto puke statističke kategorije, takvi cjenovni šokovi postaju izravna prijetnja financijskoj stabilnosti, pogotovo u kućanstvima čiji proračunski okviri nemaju potrebnu fleksibilnost za apsorpciju nepredviđenih troškova. Povezana literatura o energetskom siromaštvu dodatno rasvjetljava ovaj problem kroz prizmu jaza u energetskoj učinkovitosti; siromašnija kućanstva često su zaključana u korištenju zastarjelih i neefikasnih uređaja, poput zamrzivača, koje nisu u mogućnosti zamijeniti modernijim alternativama. Gerarden, Newell i Stavins (2017) sistematiziraju ovaj jaz kroz tržišne neuspjehe poput informacijskih asimetrija i kapitalnih ograničenja, ali i kroz bihevioralne čimbenike poput nepažnje, što objašnjava zašto kućanstva ne usvajaju tehnologije koje su čak i privatno financijski isplative. Dugoročna ranjivost takvih kućanstava na energetske šokove jasno se ocrtava i kroz rezultate LASSO regresije provedene u ovom istraživanju. Zanimljivo je da su upravo posjedovanje automobila i zamrzivača identificirani kao snažni pozitivni prediktori; ti faktori, naime, bitno determiniraju stupanj izloženosti kućanstva inflacijskim pritiscima. Automobil u tom smislu ne predstavlja samo imovinu, već i nužnost koja generira visoku osjetljivost na fluktuacije cijena goriva, dok nemogućnost investiranja u energetski učinkovitije uređaje dodatno produbljuje inflacijski jaz.

U hrvatskom kontekstu, poseban izazov predstavlja razdoblje nakon 2022. godine. Uvođenje eura 1. siječnja 2023. godine imalo je značajan utjecaj na percepciju inflacije, koja je često premašivala stvarnu izmjerenu inflaciju. Arčabić (2025) ističe da su, iako je izravan učinak konverzije na opću razinu cijena bio relativno ograničen, psihološki učinak i heterogenost u stvarnoj izloženosti kućanstava stvorili snažan osjećaj gubitka kupovne moći. Dinamika cijena u 2024. godini bila je pod snažnim utjecajem stabilizacije energetskog sektora, što je, prema podacima Hrvatske narodne banke (2025), bio primarni pokretač usporavanja inflacije. Ipak, uslužne djelatnosti i dalje generiraju pritisak koji stopu rasta cijena u Hrvatskoj održava iznad prosjeka europodručja, čime se otežava potpuna stabilizacija troškova života.

3. PODACI I METODOLOGIJA

3.1. Izvori podataka

Empirijska analiza temelji se na mikropodacima iz Ankete o potrošnji kućanstava koju provodi Državni zavod za statistiku (DZS). APK sadrži detaljne dnevnike potrošnje prema Klasifikaciji osobne potrošnje prema namjeni (COICOP), kao i bogat skup podataka o socioekonomskim karakteristikama kućanstava, njihovim prihodima i posjedovanju trajne imovine. Za potrebe rada korišteni su podaci iz anketa za 2019. i 2022. godinu. Riječ je o reprezentativnim uzorcima koji obuhvaćaju 1.809 kućanstava za 2019. te 1.391 kućanstava za 2022. godinu. Finalni uzorak za 2022. godinu predstavlja smanjenje u odnosu na prethodne valove istraživanja što je primarno odraz niske stope odgovora od 28,1 posto zabilježene u 2022. godini, ali i rigoroznog procesa validacije podataka koji provodi DZS. Naime, razlika između inicijalno anketiranih i finalno obrađenih kućanstava proizlazi iz isključivanja dnevnika potrošnje s nepotpunim ili nekonzistentnim zapisima, čime se osigurava visoka pouzdanost preostalih mikropodataka nužnih za precizan izračun individualne inflacije. Unatoč manjoj veličini finalnog uzorka, reprezentativnost na razini populacije osigurana je DZS-ovom metodologijom dvoetapnoga stratificiranog uzorka (izvučenog iz Popisa stanovništva) te primjenom kalibracijskih pondera. Ti ponderi

korigiraju utjecaj neodgovora i osiguravaju da struktura uzorka odgovara demografskim karakteristikama ukupne populacije. Povrh toga, strukturna analiza potrošačke košarice pokazuje visoku konzistentnost s povijesnim trendovima (poput Engelova zakona u nižim decilima), što potvrđuje da pad stope odgovora nije narušio temeljnu pouzdanost distribucijskih nalaza.

Osim mikropodataka o potrošnji, korišteni su službeni indeksi potrošačkih cijena DZS-a za 12 osnovnih COICOP kategorija. Ovi indeksi služe kao osnova za izračun individualnih stopa inflacije, pri čemu se ponderi potrošnje svakog kućanstva usklađuju s obuhvatom pondera iz službenih izračuna IPC-a u Hrvatskoj.

3.2. Izračun inflacije na razini kućanstva

Metodologija izračuna inflacije za svako pojedino kućanstvo prati pristup Rubil i sur. (2024). Individualna stopa inflacije za kućanstvo izračunava se kao umnožak indeksa cijena za 12 osnovnih COICOP kategorija i odgovarajućih pondera potrošnje tog kućanstva iz APK-a.

$$householdinflation_{i,t} = \sum_{c=1}^{12} w_{i,c} \cdot p_{c,t}$$

Gdje $w_{i,c}$ predstavlja ponder potrošnje kućanstva i u kategoriji c, a p_{ct} indeks cijena COICOP kategorije c u mjesecu t.

Za razdoblje od 2019. do 2021. godine korišteni su ponderi iz APK za 2019. godinu, dok se za razdoblje od 2022. do 2025. godine koriste ponderi iz APK za 2022. godinu. Analiza obuhvaća specifične mjesečne epizode, poput studenog 2022. godine, kao i objedinjene serije podataka kroz duže razdoblje. Studeni 2022. godine odabran je za jednoepizodnu analizu jer predstavlja vrhunac inflacijskog pritiska u promatranom razdoblju, s najvišom zabilježenom stopom inflacije u Hrvatskoj (13,5 posto). Fokus na ovaj mjesec omogućuje uvid u maksimalnu heterogenost izloženosti kućanstava u trenutku najjačeg cjenovnog šoka.

Iako baze APK iz 2019. i 2022. predstavljaju ponovljene poprečne presjeke (engl. *repeated cross-sections*), konstrukcija individualnih stopa inflacije na mjesečnoj razini omogućuje analizu distribucijskih učinaka kroz vrijeme primjenom pseudo-panel pristupa. Ovaj se pristup temelji na pretpostavci nepromijenjene strukture potrošnje unutar promatranih podrazdoblja, što je u skladu s metodologijom izračuna službenih indeksa cijena. Iako takva pretpostavka omogućuje izolaciju izravnog utjecaja cjenovnih šokova na različite skupine kućanstava, ona ujedno predstavlja i metodološko ograničenje jer zanemaruje potencijalne supstitucijske učinke unutar same krize. Važno je istaknuti kako Charalambakis i sur. (2022) nalaze da je kod niskodohodovnih skupina taj prostor za prilagodbu izrazito ograničen zbog visokog udjela nužnih dobara s niskom cjenovnom elastičnošću potražnje. Budući da tim kućanstvima u košarici dominiraju egzistencijalne stavke koje je nemoguće jednostavno supstituirati, pretpostavka o jednakosti strukture potrošnje unutar podrazdoblja služi kao adekvatan aproksimator stvarne izloženosti kućanstava u uvjetima naglih i sveobuhvatnih cjenovnih šokova.

3.3. Ekonometrijska specifikacija

Kako bi se utvrdile determinante nejednakosti inflacije, procjenjuju se regresijski modeli sljedećeg oblika:

$$householdinflation_i = \beta^T X_i + \gamma^T Z_i + \epsilon_i$$

U gornjoj jednadžbi, X_i predstavlja vektor osnovnih karakteristika kućanstva (veličina kućanstva, ukupni dohodak, prosječna dob, spol i razina obrazovanja ispitanika te ekvivalizirani dohodak). Vektor Z_i sadrži specifične indikatore ovisne o specifikaciji modela, kao što su status zaposlenosti (zaposleni, umirovljenici) ili indikator za samce. Za pseudo-panel analizu model se proširuje fiksnim efektima mjeseca (α_t):

$$householdinflation_{i,t} = \beta^T X_{i,t} + \gamma^T Z_{i,t} + \alpha_t + \epsilon_{i,t}$$

Uvođenje fiksnih efekata mjeseca (α_t) omogućuje kontrolu zajedničkih makroekonomskih šokova koji pogađaju sva kućanstva istovremeno, poput promjena u globalnim cijenama energenata ili nacionalnih mjera ekonomske politike. Time se u modelu izolira utjecaj isključivo

socioekonomskih karakteristika kućanstava na njihove individualne stope inflacije.

Ekvivalizirani dohodak izračunat je primjenom modificirane OECD-ove ljestvice radi osiguravanja usporedivosti kućanstava različitog sastava i veličina.

3.4. Selekcija varijabli i metodološki okvir (LASSO regresija)

Zbog velikog broja koreliranih varijabli u APK i rizika od prekomjernog prilagođavanja, primijenjena je LASSO regresija (Mullainathan i Spiess, 2017) za automatsku selekciju najvažnijih prediktora. Metoda penalizacijom svodi koeficijente manje važnih varijabli na nulu, čime se izoliraju ključna demografska obilježja i utjecaj posjedovanja imovine (poput automobila ili zamrzivača) na individualnu inflaciju.

Sve su nezavisne varijable standardizirane, a model je procijenjen kao objedinjena ponderirana regresija u softveru R (paket *glmnet*). Optimalna razina penalizacije (λ) određena je k-strukom unakrsnom provjerom (engl. *k-fold cross-validation*) uz odabir parametra koja minimizira srednju pogrešku (λmin).

4. EMPIRIJSKI REZULTATI

4.1. Deskriptivna analiza i distribucija inflacije

Analiza pondera potrošnje po dohodovnim decilima potvrđuje značajne strukturne razlike u košaricama kućanstava u Hrvatskoj. Iz APK 2019. 10 posto kućanstava s najnižim dohotkom (prva dohodovna decilna skupina) trošilo je čak 43,0 posto svog budžeta na hranu, dok je taj udio kod 10 posto kućanstava s najvišim dohotkom (deseta decilna skupina) znatno niži i iznosio je 21,9 posto. Slična regresivna struktura uočljiva je i kod troškova stanovanja i režija (23,8 posto za prvi naspram 14,4 posto za deseti decil). S druge strane, kućanstva s višim dohotkom značajnije veći udio dohotka usmjeravaju na transport (15,8 posto) i restorane (5,2 posto) u usporedbi s kućanstvima s najnižim dohotkom. Važno je istaknuti da su se ponderi prema APK iz 2022. nešto promijenili. Najveća promjena zabilježena je kod pondera za hranu kućanstava s najnižim dohotkom koji se smanjio na 38,5 posto, a kod onih s najvišim dohotkom povećao na 22,4 posto te kod restorana čiji se ponder kod kućanstava s najvišim dohotkom povećao na 8,0 posto.

Slika 1 prikazuje prosječnu stopu inflacije za kućanstva koja se prema dohotku nalaze u prvoj i desetoj dohodovnoj decilnoj skupini, dakle za 10 posto kućanstava s najnižim i 10 posto onih s najvišim dohotkom. Iz grafikona je vidljivo da su se do početka 2021. godine stope inflacije obiju skupina kretale relativno sinkronizirano uz niske stope rasta. Međutim, s nastupom energetske krize i snažnog rasta cijena hrane krajem 2021. godine, dolazi do značajne divergencije. U trenutku kada inflacija doseže svoj vrhunac u studenom 2022. godine, stopa inflacije za 10 posto kućanstava s najnižim dohotkom (puna linija) bila je osjetno viša (14,7 posto) u usporedbi s kućanstvima s najvišim dohotkom (točkasta linija), kod kojih se zadržala na razini od 13,1 posto. Ova razlika potvrđuje hipotezu o regresivnom karakteru inflacije, gdje porast cijena osnovnih dobara jače pogađa kućanstva s nižim raspoloživim dohotkom. Tijekom 2023. godine vidljiv je trend snažnog pada inflacije za obje skupine, pri čemu se inflacijski jaz privremeno smanjio. Inflacijski pritisci ponovno jačaju prema sredini 2025. godine, s tim da je taj trend znatno agresivniji kod kućanstava s najnižim dohotkom. Dok su kućanstva s višim dohotkom ranije bila pogođena rastom cijena luksuza i usluga, trenutna dinamika sugerira povratak troškovnog udara na osnovne egzistencijalne kategorije. Dok se inflacija za 10 posto kućanstava s najvišim dohotkom stabilizirala ispod 4 posto, kućanstva s najnižim dohotkom ponovno bilježe stope iznad 5 posto, što sugerira novi val pritiska na njihovu kupovnu moć. Reprezentativnost službene stope inflacije postaje upitna upravo u trenucima šokova cijena osnovnih potrepština, kada prosječni pokazatelji zakažu u mjerenju stvarnog tereta na najugroženije. Statistički prosjek, naime, ne uspijeva adekvatno artikulirati intenzitet troškovnog pritiska koji pogađa kućanstva čija je potrošnja primarno vezana uz energiju i hranu.

Slika 2 prikazuje kretanje inflacijskog jaza kroz promatrano razdoblje, definirano kao razlika u stopi inflacije između kućanstava s najnižim

Slika 1. Prosječna stopa inflacije za 10 posto kućanstava s najmanjim i najvećim dohocima

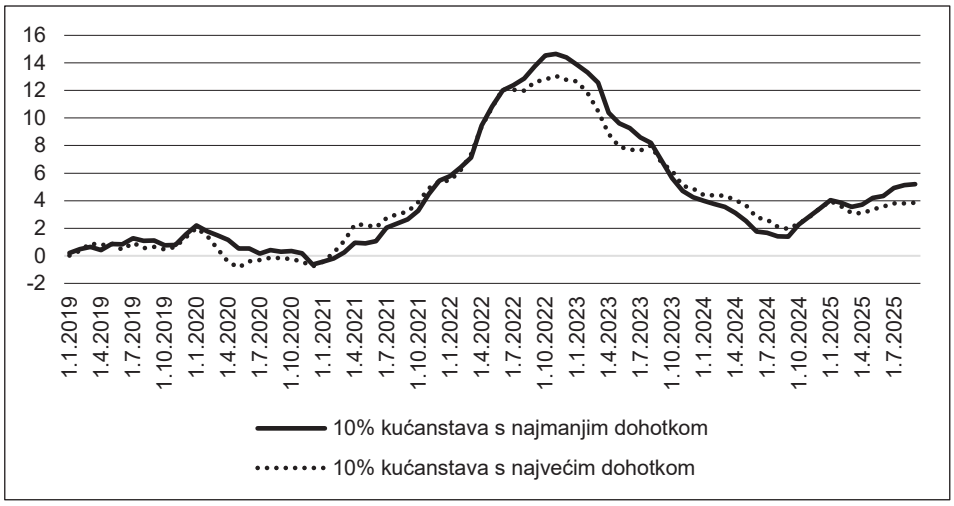

Izvori: izračun autora iz podataka Državnog zavoda za statistiku te APK 2019. i 2022.

i najvišim dohotkom. Točkasta linija prikazuje jaz između prve i desete decilne skupine (omjer 10/90), dok puna linija prikazuje jaz između ekstremnijih skupina – kućanstava koja spadaju u 5 posto onih s najnižim i 5 posto onih s najvišim dohotkom (omjer 5/95).

Grafikon jasno potvrđuje da su razlike u inflacijskom iskustvu izraženije što se više pomičemo prema rubovima distribucije dohotka. Puna linija (5/95) gotovo konzistentno bilježi veće amplitude u odnosu na točkastu liniju (10/90). To sugerira da kućanstva s najnižim dohotkom (donjih 5 posto) trpe značajno veći relativni troškovni pritisak čak i u usporedbi s ostatkom donjeg dohodovnog decila. Najveći jaz bilježi se u drugoj polovici 2022. i početkom 2023. godine, kada razlika za ekstremne skupine (5/95) premašuje dva postotna boda. Najveći jaz za skupinu 5/95 od 2,1 postotna boda dosegnut je u ožujku 2023. godine. Ovo je razdoblje vrhunca cijena hrane i energije, dobara koja čine dominantan udio u rashodima kućanstava s najnižim dohotkom. Činjenica da jaz raste upravo u trenucima visoke inflacije ukazuje na to da inflacija u Hrvatskoj ima snažan regresivni učinak. Tijekom 2024. godine primjećuje se zanimljiv trend pada jaza u negativno područje. To znači da su u tom specifičnom podrazdoblju kućanstva s višim dohotkom privremeno imala višu stopu inflacije od onih s nižim dohotkom, što se može objasniti bržim rastom cijena usluga, putovanja i luksuznih dobara, dok su cijene bazičnih namirnica stagnirale ili rasle sporije. Prema kraju promatranog razdoblja, oba jaza ponovno snažno rastu i sinkronizirano prelaze u pozitivno područje (iznad 1,5 postotnih bodova). Ovaj ponovni rast jaza u 2025. godini signalizira da se nejednakost opet produbljuje, pri čemu ekstremne skupine (5/95) ponovno predvode u izloženosti. Kretanje inflacijskog jaza pokazuje da se socijalna stratifikacija inflacije ne događa linearno, već se intenzivira na samim polovima dohodovne ljestvice. Razlika od preko 2 postotna boda u jeku krize predstavlja značajan udar na kupovnu moć onih koji ionako troše najveći dio dohotka na egzistencijalna dobra.

Slika 3 prikazuje da je prema podacima do rujna 2025. godine, kumulativni porast troškova života od 2019. godine za 10 posto kućanstava s najnižim dohotkom iznosio ukupno 33,6 posto, dok je za 10 posto kućanstava s najvišim dohotkom taj porast bio niži i iznosio je 31,1 posto. Vidljivo je da službeni IPC gotovo u potpunosti prati kretanje decila s najvišim dohotkom, dok značajno podcjenjuje stvarni rast troškova života za kućanstva s najnižim dohotkom. Ovaj nalaz potvrđuje da relativni cjenovni šokovi, primarno u kategorijama hrane i energije, nisu imali samo

Slika 2. Razlika u stopama inflacije između 5 posto/10 posto kućanstava s najnižim odnosno najvišim dohotkom

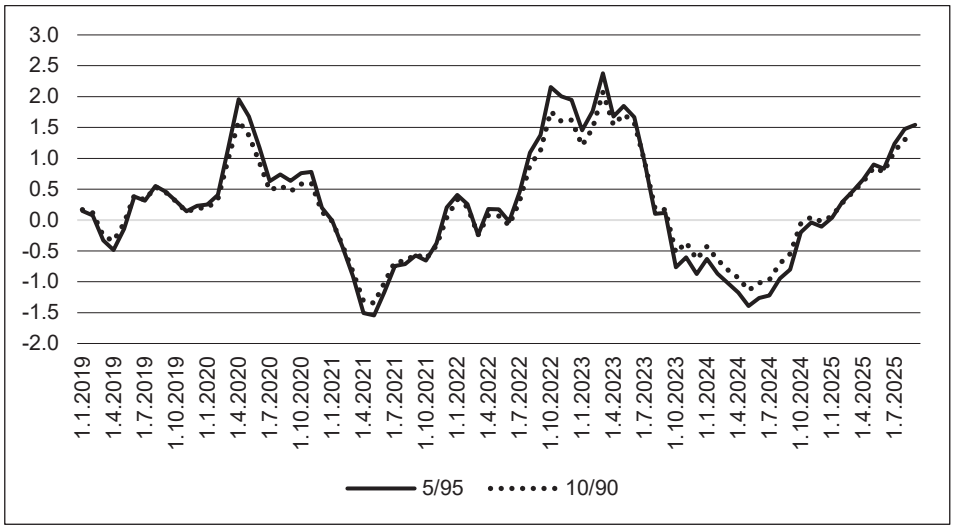

Izvori: izračun autora iz podataka Državnog zavoda za statistiku te APK 2019. i 2022.
Napomena: Točkasta linija prikazuje jaz između prve i desete decilne skupine (omjer 10/90), dok puna linija prikazuje jaz između ekstremnijih skupina – kućanstava koja spadaju u 5 posto onih s najnižim i 5 posto onih s najvišim dohotkom (omjer 5/95).

Slika 3. Kumulativna stopa inflacije (2019 = 100)

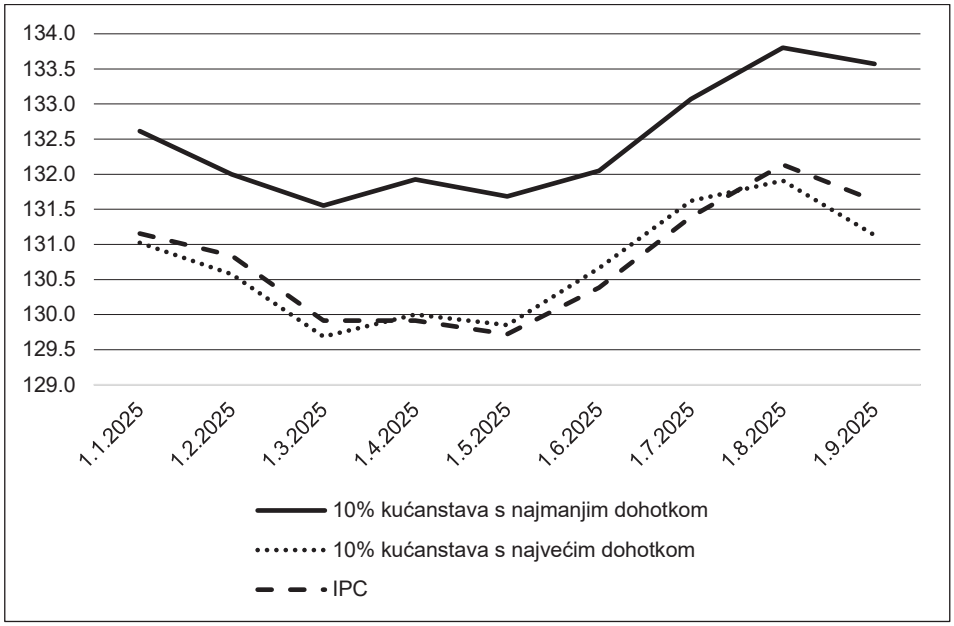

Izvori: izračun autora iz podataka Državnog zavoda za statistiku te APK 2019. i 2022.

Tablica 1. Rezultati pseudo-panel regresija za studeni 2022. godine.

	Model 1	Model 2	Model 3	Model 4
Konstanta	12.80*** (0.23)	12.70*** (0.22)	12.67*** (0.22)	13.32*** (0.16)
Veličina kućanstva	0.13*** (0.04)	0.14*** (0.04)	0.14*** (0.04)	-
Dohodak	-0.00*** (0.00)	-0.00*** (0.00)	-0.00*** (0.00)	-
Ekvivalizirani dohodak	-	-	-	-0.00*** (0.00)
Dob	0.02*** (0.003)	0.02*** (0.003)	0.02*** (0.003)	0.02*** (0.002)
Spol	0.00 (0.07)	0.00 (0.07)	0.01 (0.07)	-0.02 (0.07)
Visoko obrazovanje	-0.29** (0.09)	-0.30** (0.09)	-0.30** (0.09)	-0.20* (0.09)
Zaposlen	-0.11 (0.08)	-	-	-0.06 (0.08)
Umirovljenik	-	0.07 (0.09)	-	-
Samac	-	-	-0.01 (0.10)	-
Standardna pogreška	1.18	1.18	1.18	1.17
Koeficijent determinacije	0.20	0.20	0.20	0.21
Korigirani koeficijent determinacije	0.19	0.19	0.19	0.21
F-statistika	56.82	56.61	56.48	73.98

Izvori: izračun autora iz podataka Državnog zavoda za statistiku te APK 2019. i 2022.
Napomene: Vrijednosti u zagradama predstavljaju robusne standardne pogreške. Razine značajnosti: *** $p < 0,001$; ** $p < 0,01$; * $p < 0,05$.

tranzitorni učinak, već su doveli do trajnog i neravnomjernog smanjenja realnog standarda.

4.2. Regresijski nalazi za objedinjene ponovljene poprečne presjeke

Rezultati procjena za različita razdoblja ukazuju na stabilne i statistički značajne determinante individualne stope inflacije (Tablice 1–4). Ukupni dohodak kućanstva dosljedno pokazuje negativan predznak u svim specifikacijama, što potvrđuje da veći dohodak djeluje kao zaštitni faktor protiv visoke inflacije u svim analiziranim razdobljima. Konkretno, prema rezultatima Modela 1 (Tablica 4), koeficijent uz varijablu dohotka iznosi −0,000008 (zaokruženo na −0,00 u tabličnom prikazu). Iako je marginalni učinak dohotka brojčano malen, važno je naglasiti da je on procijenjen uz strogu kontrolu fiksnih vremenskih efekata koji apsorbiraju najveći dio varijance u cijenama. Stoga, izolirani koeficijent

Tablica 2. Rezultati pseudo-panel regresija za razdoblje od 2019. do 2021. godine.

	Model 1	Model 2	Model 3	Model 4
Dohodak	-0.00* (0.00)	-0.00* (0.00)	-0.00 (0.00)	-
Veličina kućanstva	-0.03*** (0.003)	-0.02*** (0.003)	-0.02*** (0.004)	-0.03*** (0.003)
Dob	0.00*** (0.00)	0.00*** (0.00)	0.00** (0.00)	0.00** (0.00)
Spol	-0.07*** (0.01)	-0.07*** (0.01)	-0.08*** (0.01)	-0.07*** (0.01)
Visoko obrazovanje	-0.00 (0.01)	-0.00 (0.01)	0.00 (0.01)	0.00 (0.01)
Zaposlen	0.01 (0.01)	-	-	0.01 (0.01)
Umirovljen	-	-0.03*** (0.01)	-	-
Samac	-	-	0.02** (0.01)	-
Ekvivalizirani dohodak	-	-	-	-0.00** (0.00)
Korijen srednje kvadratne pogreške	0.76	0.76	0.76	0.76
Korigirani koeficijent determinacije	0.77	0.77	0.77	0.77
Koeficijent determinacije unutar skupina	0.01	0.01	0.01	0.01
Broj opažanja	64,944	64,944	64,944	64,944
Fiksni efekti	mjesec	mjesec	mjesec	mjesec

Izvori: izračun autora iz podataka Državnog zavoda za statistiku te APK 2019. i 2022.
Napomene: Vrijednosti u zagradama predstavljaju robusne standardne pogreške. Razine značajnosti: *** $p < 0{,}001$; ** $p < 0{,}01$; * $p < 0{,}05$.

ukazuje na to da dohodak *per se*, neovisno o općim tržišnim trendovima, predstavlja statistički visokoznačajnu barijeru izloženosti inflacijskim šokovima.

Nizak intenzitet koeficijenta dohotka može se djelomično objasniti i snažnim utjecajem visokog obrazovanja, koje u Modelima 1–3 (Tablica 1) bilježi visokoznačajan i ekonomski snažan negativan učinak od −0,20 do −0,30. Budući da su dohodak i stupanj obrazovanja u snažnom korelacijskom odnosu, značajan dio zaštitnog učinka koji se teoretski pripisuje kupovnoj moći zapravo se očituje kroz varijablu obrazovanja. To sugerira da obrazovanija kućanstva ne postižu nižu stopu inflacije samo zbog viših primanja, već i zbog naprednijih potrošačkih strategija, poput veće fleksibilnosti u supstituciji dobara, efikasnijeg

Tablica 3. Rezultati pseudo-panel regresija za razdoblje od 2022. do 2025. godine.

	Model 1	Model 2	Model 3	Model 4
Dohodak	-0.00*** (0.00)	-0.00*** (0.00)	-0.00*** (0.00)	-
Veličina kućanstva	0.03*** (0.005)	0.03*** (0.005)	0.04*** (0.005)	0.00 (0.004)
Dob	0.01*** (0.00)	0.01*** (0.00)	0.01*** (0.00)	0.01*** (0.00)
Spol	0.03*** (0.01)	0.03*** (0.01)	0.03*** (0.01)	0.03*** (0.01)
Visoko obrazovanje	0.01 (0.01)	0.00 (0.01)	0.00 (0.01)	0.03* (0.01)
Zaposlen	-0.04** (0.01)	-	-	-0.02 (0.01)
Umirovljen	-	0.03** (0.01)	-	-
Samac	-	-	0.00 (0.01)	-
Ekvivalizirani dohodak	-	-	-	-0.00*** (0.00)
Korijen srednje kvadratne pogreške	1.03	1.03	1.03	1.03
Korigirani koeficijent determinacije	0.94	0.94	0.94	0.94
Koeficijent determinacije unutar skupina	0.02	0.02	0.02	0.02
Broj opažanja	62,415	62,415	62,415	62,415
Fiksni efekti	mjesec	mjesec	mjesec	mjesec

Izvori: izračun autora iz podataka Državnog zavoda za statistiku te APK 2019. i 2022.
Napomene: Vrijednosti u zagradama predstavljaju robusne standardne pogreške. Razine značajnosti: *** p < 0,001; ** p < 0,01; * p < 0,05.

korištenja informacija o cijenama i pristupa širem spektru prodajnih kanala, što im omogućuje uspješnije izbjegavanje najsnažnijih cjenovnih udara (D'Acunto, Malmendier i Weber, 2023).

Važno je naglasiti da su dobiveni rezultati visoko robusni na promjenu specifikacije varijable dohotka. Prilikom testiranja modela s ekvivaliziranim dohotkom umjesto ukupnog dohotka (Model 4 u svim tablicama), ključni koeficijenti zadržavaju svoj predznak, razinu signifikantnosti ($p<0,01$) i ekonomski intenzitet. To potvrđuje da regresivni karakter inflacije ne ovisi o načinu mjerenja kupovne moći kućanstva, već je duboko ukorijenjen u strukturu potrošnje.

Prosječna dob kućanstva ima pozitivan i visoko značajan utjecaj u svim modelima, sugerirajući

da starija kućanstva u Hrvatskoj snose veći teret inflacije. Posebno se ističe Tablica 1 (studeni 2022.) gdje je koeficijent dobi najviši (0,02), što ukazuje na to da su u jeku krize starija kućanstva bila dodatno ranjiva. S druge strane, visoko obrazovanje (Tablica 1, Modeli 1-3) pokazuje značajan negativan utjecaj (−0,30), što upućuje na to da viši ljudski kapital omogućuje bolju alokaciju resursa i izbor košarice koja je manje pogođena ekstremnim skokovima cijena.

Zanimljivo je uočiti promjenu predznaka varijable spola između dva ključna podrazdoblja. Dok je u poduzorku 2019. – 2021. (Tablica 2) ženski spol ispitanika bio povezan s nižom individualnom inflacijom (−0,07), u razdoblju najintenzivnije krize 2022. – 2025. (Tablica 3) taj učinak postaje pozitivan (0,03). Ova promjena sugerira duboku strukturnu transformaciju prirode inflacijskih pritisaka. U razdoblju niske i stabilne inflacije, negativan koeficijent može se pripisati većoj sklonosti žena detaljnom planiranju kupnje i potrazi za cjenovnim pogodnostima, što im omogućuje ostvarivanje nižih cijena za istu košaricu dobara (D'Acunto, Malmendier i Weber, 2021). Nakon 2022. godine, inflacijsku su dinamiku presudno odredili egzogeni potresi na tržištima hrane i energije. Za kućanstva kojima upravljaju žene, a koja su nerijetko jednoroditeljska ili samačka (starije dobi), to je značilo dramatičan porast pritiska na ionako nategnute budžete u kojima dominiraju režije i osnovne potrepštine. Prema nalazima Charalambakis, Fagandini, Henkel i Osbat (2022), takva struktura izdataka izravno ih svrstava u skupinu s najvećim rizikom od inflacijskih udara, budući da nemaju prostora za smanjenje diskrecijske potrošnje. U takvim okolnostima, prednosti individualnih strategija upravljanja kupnjom poništene su nepovoljnom strukturom košarice.

Dodatnu dimenziju ranjivosti otkriva varijabla samaca (Tablica 2, Model 3), koja u razdoblju 2019. – 2021. pokazuje pozitivan i statistički značajan koeficijent (0,02). Ovaj nalaz sugerira da kućanstva s jednim članom sustavno doživljavaju višu stopu inflacije u usporedbi s višečlanim kućanstvima, *ceteris paribus*. Takav ishod primarno proizlazi iz otežanog ostvarivanja ekonomije obujma kod nabave hrane i fiksnih režijskih troškova, koji u proračunu samaca predstavljaju razmjerno veće opterećenje. To što navedeni koeficijent gubi na statističkoj značajnosti u kasnijoj fazi krize (Tablica 3), sugerira da su ekstremni cjenovni šokovi nakon 2022. godine postali toliko sveobuhvatni da su zasjenili razlike temeljene na broju članova. Čini se da je regresivni učinak cijena osnovnih dobara bio toliko snažan da je pogodio sve niske dohodovne skupine, neovisno o veličini kućanstva.

Uočava se i promjena u utjecaju veličine kućanstva. Dok je u početnom razdoblju (Tablica 2) veće kućanstvo značilo nižu inflaciju (−0,03), vjerojatno zbog ekonomije obujma u kupnji, u kriznom razdoblju (Tablica 3) taj koeficijent postaje pozitivan (0,03). To ukazuje na to da su u uvjetima snažnog rasta cijena hrane, veća kućanstva (koja troše apsolutno više na prehranu) izgubila prednost ekonomije obujma pred linearnim i agresivnim rastom cijena osnovnih namirnica.

Vrijednosti koeficijenata determinacije unutar skupina vrijednosti koje se kreću od 0,01 do 0,02 sugeriraju da socioekonomske karakteristike kućanstava objašnjavaju svega jedan do dva posto varijacije individualnih stopa inflacije unutar promatranih razdoblja. Ovako niska vrijednost očekivana je u modelima s fiksnim efektima vremena, budući da su individualne stope inflacije primarno determinirane zajedničkim makroekonomskim šokovima koji pogađaju sva kućanstva istovremeno. Iako je doprinos analiziranih varijabli brojčano malen, njihova visoka statistička značajnost potvrđuje da razlike u inflacijskom iskustvu nisu nasumične, već sustavno povezane s kupovnom moći i strukturom potrošnje. U tom kontekstu, socioekonomske varijable identificirane su kao ključne odrednice relativnih odstupanja od prosječne stope inflacije, što potvrđuje regresivni karakter inflacijskih pritisaka u Hrvatskoj.

4.3. Interakcijski efekti i rezultati za najniži decil

Dodatni uvid u mehanizme zaštite pružaju interakcijski efekti (Tablica 5). Model 1 uvodi interakciju dohotka i visokog obrazovanja s pozitivnim koeficijentom. Ovaj nalaz sugerira da obrazovanje djeluje kao ključan moderator izloženosti: viša razina obrazovanja pruža najsnažniju

Tablica 4. Rezultati pseudo-panel regresija za razdoblje od 2019. do 2025. godine.

	Model 1	Model 2	Model 3	Model 4
Dohodak	-0.00*** (0.00)	-0.00*** (0.00)	-0.00*** (0.00)	-
Veličina kućanstva	0.00 (0.003)	0.00 (0.003)	0.01 (0.003)	-0.01*** (0.003)
Dob	0.00*** (0.00)	0.00*** (0.00)	0.00*** (0.00)	0.00*** (0.00)
Spol	-0.02*** (0.01)	-0.02*** (0.01)	-0.02*** (0.01)	-0.02*** (0.01)
Visoko obrazovanje	0.00 (0.01)	0.00 (0.01)	0.00 (0.01)	0.01 (0.01)
Zaposlen	-0.01 (0.01)	-	-	-0.00 (0.01)
Umirovljen	-	-0.00 (0.01)	-	-
Samac	-	-	0.01 (0.01)	-
Ekvivalizirani dohodak	-	-	-	-0.00*** (0.00)
Korijen srednje kvadratne pogreške	0.91	0.91	0.91	0.91
Korigirani koeficijent determinacije	0.95	0.95	0.95	0.95
Koeficijent determinacije unutar skupina	0.01	0.01	0.01	0.01
Broj opažanja	127,359	127,359	127,359	127,359
Fiksni efekti	mjesec	mjesec	mjesec	mjesec

Izvori: izračun autora iz podataka Državnog zavoda za statistiku te APK 2019. i 2022.
Napomene: Vrijednosti u zagradama predstavljaju robusne standardne pogreške. Razine značajnosti: *** p < 0,001; ** p < 0,01; * p < 0,05.

zaštitu upravo kod niskodohodovnih kućanstava. U tim uvjetima, ljudski kapital služi kao alat za aktivnu supstituciju dobara (npr. prelazak na trgovačke marke) i strateško upravljanje oskudnim proračunom. Međutim, kako dohodak raste, ovaj zaštitni efekt obrazovanja slabi. Za kućanstva s višim dohotkom, marginalna korist vremena utrošenog na potragu za nižim cijenama manja je od oportunitetnog troška tog vremena, zbog čega dohodak preuzima primarnu ulogu u amortizaciji šokova.

Zanimljiv nalaz donosi i interakcija dobi i zaposlenosti (Tablica 5, Model 3) koja je negativna i značajna. To implicira da zaposlenost djeluje kao snažniji zaštitni faktor za starije radnike u usporedbi s mlađima, vjerojatno zbog stabilnosti dohodaka i specifičnih struktura potrošnje

Tablica 5. Rezultati pseudo-panel regresija s interakcijama za razdoblje od 2019. do 2025. godine.

	Model 1	Model 2	Model 3	Model 4
Dohodak	-0.00*** (0.00)	-0.00*** (0.00)	-0.00*** (0.00)	-0.00*** (0.00)
Visoko obrazovanje	-0.12*** (0.02)	0.01 (0.02)	0.00 (0.01)	0.02* (0.01)
Veličina kućanstva	-0.01* (0.00)	-0.02*** (0.00)	0.00 (0.00)	0.00 (0.00)
Dob	0.00*** (0.00)	0.00*** (0.00)	0.00*** (0.00)	0.00*** (0.00)
Spol	-0.02*** (0.01)	-0.03*** (0.00)	-0.02*** (0.01)	-0.03*** (0.01)
Zaposlen	-0.00 (0.01)	-0.01 (0.47)	0.09*** (0.02)	-
Samac	-	-	-	0.10*** (0.01)
Decilna skupina	-	-	-	0.00 (0.00)
Dohodak x visoko obrazovanje	0.00*** (0.00)	-	-	-
Dohodak x veličina kućanstva	-	0.00 (0.07)	-	-
Dob x zaposlen	-	-	-0.00*** (0.00)	-0.00*** (0.00)
Decilna skupina x samac	-	-	-	-0.02*** (0.00)
Korijen srednje kvadratne pogreške	0.91	0.91	0.91	0.91
Korigirani koeficijent determinacije	0.95	0.95	0.95	0.95
Koeficijent determinacije unutar skupina	0.01	0.01	0.01	0.01
Broj opažanja	127,359	127,359	127,359	127,359
Fiksni efekti	mjesec	mjesec	mjesec	mjesec

Izvori: izračun autora iz podataka Državnog zavoda za statistiku te APK 2019. i 2022.
Napomene: Vrijednosti u zagradama predstavljaju robusne standardne pogreške. Razine značajnosti: *** $p < 0,001$; ** $p < 0,01$; * $p < 0,05$.

Tablica 6. Rezultati pseudo-panel regresija za najniži dohodovni decil za razdoblje od 2019. do 2025. godine.

	Model 1	Model 2	Model 3	Model 4
Dohodak	-0.00*** (0.00)	-0.00*** (0.00)	-0.00*** (0.00)	-
Veličina kućanstva	0.02* (0.01)	0.02* (0.01)	0.06*** (0.01)	-0.02** (0.01)
Dob	0.00*** (0.00)	0.00*** (0.00)	0.00*** (0.00)	0.00*** (0.00)
Spol	-0.11*** (0.01)	-0.11*** (0.01)	-0.16*** (0.01)	-0.11*** (0.01)
Visoko obrazovanje	-0.07 (0.06)	-0.09 (0.06)	-0.07 (0.06)	-0.09 (0.06)
Zaposlen	-0.07 (0.04)	-	-	-0.08* (0.04)
Umirovljen	-	-0.01 (0.02)	-	
Samac	-	-	0.19*** (0.02)	-
Ekvivalizirani dohodak	-	-	-	-0.00*** (0.00)
Korijen srednje kvadratne pogreške	0.76	0.76	0.76	0.76
Korigirani koeficijent determinacije	0.97	0.97	0.97	0.97
Koeficijent determinacije unutar skupina	0.02	0.01	0.02	0.02
Broj opažanja	14,418	14,418	14,418	14,418
Fiksni efekti	mjesec	mjesec	mjesec	mjesec

Izvori: izračun autora iz podataka Državnog zavoda za statistiku te APK 2019. i 2022.
Napomene: Vrijednosti u zagradama predstavljaju robusne standardne pogreške. Razine značajnosti: *** p < 0,001; ** p < 0,01; * p < 0,05.

koje su manje osjetljive na volatilnost cijena u usporedbi s umirovljeničkim kućanstvima iste dobi. Naposljetku, Model 4 u Tablici 5 uvodi interakciju samačkog statusa i dohodovnog decila. Rezultati pokazuju da je osnovni učinak samačkog života na inflaciju izrazito pozitivan, dok je interakcijski član negativan. Ovakva dinamika sugerira da se inflacija samaca linearno smanjuje s porastom kupovne moći, što potvrđuje da je samački status primarno faktor rizika na dnu distribucije dohotka.

S druge strane, u najnižem dohodovnom decilu (Tablica 6, Model 4), zaposlenost sama po sebi smanjuje inflaciju za 0,08 postotnih bodova, što naglašava važnost participacije na tržištu rada

kao brane protiv apsolutnog osiromašenja u inflacijskim krizama.

Analiza najnižeg dohodovnog decila (Tablica 6) otkriva postojanje značajne heterogenosti, što ukazuje na to da niska razina dohotka sama po sebi nije jedini prediktor ekstremne izloženosti inflaciji. Čak i unutar ove, najugroženije skupine, marginalni porast dohotka zadržava svoj zaštitni karakter (koeficijent −0,00), sugerirajući da oni s najnižim dohocima među onima s već niskim dohocima snose nesrazmjerno najveći teret cjenovnih šokova.

Posebno su upečatljivi rezultati za kućanstva samaca unutar prvog decila (Tablica 6, Model 3), s izrazito visokim i značajnim koeficijentom od 0,19. Ekonomsko objašnjenje za ovakvu ranjivost leži u nemogućnosti ostvarivanja ekonomije obujma. Osim što fiksni troškovi stanovanja i režija u potpunosti opterećuju proračun samo jednog člana, samci se suočavaju s dodatnim financijskim opterećenjima koje Caplovitz (2025) opisuje kao „premiju za siromašne" (engl. *poverty premium*). Zbog ograničenih likvidnih sredstava, siromašni samci često nisu u mogućnosti prakticirati kupnju na veliko (Orhun i Palazzolo, 2019), već su prisiljeni kupovati manja i skuplja pakiranja, što dodatno podiže njihovu individualnu stopu inflacije.

U specifičnom hrvatskom kontekstu, ovaj nalaz nužno je promatrati kroz prizmu demografske slike. Samci u prvom dohodovnom decilu su nesrazmjerno zastupljeni među starijim osobama i umirovljenicima. To potvrđuje i Tablica 6, gdje varijabla dobi zadržava pozitivan predznak, stvarajući kumulativni efekt izrazite inflacijske ranjivosti za starije osobe koje žive same.

4.4. Nalazi LASSO regresije

Primjena LASSO regresije potvrdila je važnost imovinskih varijabli koje nadilaze osnovnu demografiju, pružajući precizniji uvid u determinante izloženosti inflaciji kroz prizmu životnog stila i posjedovanja trajnih dobara (Tablica 7). Za razliku od standardnih procjena, LASSO metoda je kroz proces penalizacije zadržala samo one varijable koje imaju najveću prediktivnu moć za individualnu stopu inflacije.

Tablica 7. Rezultati LASSO regresije: Ključne determinante izloženosti inflaciji

Varijabla	Koeficijent (λmin)
Konstanta	6.513
Veličina kućanstva	0.0160
Dob	0.0021
Umirovljenik	0.0217
Samac	-0.0220
Ukupni izdaci	-0.000
Dohodovni decil	-0.0023
Posjedovanje automobila	0.1600
Posjedovanje klima uređaja	-0.0340
Posjedovanje zamrzivača	0.0223
Posjedovanje drugog automobila u kućanstvu	0.0941
Najamnina	-0.000

Izvori: izračun autora iz podataka Državnog zavoda za statistiku te APK 2019. i 2022.

Rezultati ističu da su najsnažniji pozitivni prediktori izloženosti inflaciji posjedovanje automobila (0,1600) i drugog automobila u kućanstvu (0,0941). Ovi nalazi izravno reflektiraju ekstremnu osjetljivost kućanstava na rast cijena goriva i transportnih usluga koji su obilježili promatrano razdoblje. Činjenica da model prepoznaje i drugi automobil kao značajan faktor ukazuje na to da se inflacijski pritisak akumulira s intenzitetom korištenja privatnog prijevoza. Slično tome, posjedovanje zamrzivača (0,0223), koji u kućanstvima često služi kao indikator veće potrošnje električne energije ili specifičnih obrazaca skladištenja hrane, dodatno doprinosi povišenju individualne stope inflacije.

S druge strane, indikatori višeg životnog standarda, poput posjedovanja klima uređaja (-0,0340) ili viših troškova najamnine, povezani su s ni-

žom izloženosti inflaciji. Kod najamnine, iako je koeficijent brojčano malen, on u LASSO selekciji služi kao snažan prediktor urbanog i modernijeg stila života. Kućanstva koja plaćaju najamninu ili posjeduju klimatizacijske sustave u pravilu imaju košarice usmjerene prema uslugama i dobrima s nižom stopom rasta cijena u usporedbi s bazičnim artiklima (hrana i energija) koji dominiraju u kućanstvima nižeg materijalnog standarda.

Posebno je zanimljiv nalaz za varijablu koja označava samačko kućanstvo, čiji je koeficijent u LASSO modelu negativan (-0,022). Ova diskrepancija u odnosu na rezultate za najniži dohodovni decil (0,19 u Tablici 6) objašnjava se nalazima interakcijskog modela iz Tablice 5 te potvrđuje duboku heterogenost unutar same kategorije samaca. U istoj kategoriji nalaze se siromašniji samci čija je potrošnja strukturno zarobljena u troškovima hrane i energije te mlađi zaposleni stanovnici urbanih sredina. Njihov fokus na tehnologiju i ugostiteljstvo rezultirao je drugačijim inflacijskim iskustvom jer su te kategorije bilježile umjereniju dinamiku cijena od onih egzistencijalnih. Stoga LASSO model na razini cijele populacije detektira taj dominantni urbani obrazac, dok ciljana analiza onih s najnižim dohotkom (Tablica 6) uspijeva izolirati specifičnu egzistencijalnu ranjivost najugroženijih pojedinaca.

Konačno, LASSO model je zadržao varijable dobi (0,0021) i statusa umirovljenika (0,0217) kao pozitivne prediktore, čime su dodatno potvrđeni raniji nalazi o sustavnoj ranjivosti starije populacije u Hrvatskoj, neovisno o primijenjenoj metodologiji procjene.

Kvaliteta predikcije LASSO modela ocijenjena je putem srednje kvadratne pogreške (16,18) i koeficijenta determinacije (0,0018). Usporedba s OLS modelom iste specifikacije (16,47 i 0,0022) pokazuje da LASSO metoda ostvaruje veću preciznost (niža srednja kvadratna pogreška) uz značajnu redukciju kompleksnosti. Dok OLS model dodjeljuje nenulte vrijednosti svim uključenim varijablama, LASSO penalizacijom izolira samo najvažnije prediktore. Primjerice, koeficijenti za ključne faktore poput posjedovanja automobila (LASSO 0,16 naspram OLS 0,19) i zamrzivača (LASSO 0,02 naspram OLS 0,06) zadržavaju isti smjer i sličan intenzitet. S druge strane, varijabla samac u OLS modelu poprima snažniji negativan predznak (-0,10) u odnosu na LASSO procjenu (-0,02), što ukazuje na to da LASSO metoda uspješnije ublažava utjecaj multikolinearnosti i ekstremnih vrijednosti unutar heterogenog uzorka. Ovakvi rezultati opravdavaju primjenu LASSO algoritma u svrhu parsimoničnije i preciznije identifikacije strukturnih determinanti inflacije.

5. ZAKLJUČAK

Rezultati potvrđuju da je inflacija u Hrvatskoj (2019.–2025.) bila izrazito heterogena i regresivna. Dohodak je najsnažnija determinanta: kućanstva s višim dohotkom bilježe niže stope inflacije zbog veće fleksibilnosti potrošnje i manjeg udjela hrane i energije u košarici.

Analiza najnižeg dohodovnog decila otkriva da samci i višečlana kućanstva s niskim dohotkom snose najveći teret. Kod samaca nedostatak ekonomije obujma uz fiksne troškove stanovanja onemogućuje amortizaciju šokova, dok kod višečlanih obitelji dominiraju izdaci za hranu (43,1 posto). Stoga trenutni model pomoći, temeljen na fiksnim energetskim vaučerima, nije dovoljno fleksibilan. Mjere bi trebale težiti napuštanju modela univerzalnih subvencija i prelasku na precizno ciljanje koje uvažava dohodak i sastav kućanstva. Ipak, važno je naglasiti da implementacija takvih mjera podrazumijeva veće administrativne troškove i zahtijeva visoku razinu integracije službenih baza podataka, zbog čega bi se pri njihovom uvođenju trebala provesti detaljna analiza isplativosti preciznijeg obuhvata u odnosu na troškove same provedbe.

Primjena LASSO regresije ukazala je na važnost imovine kao preciznijeg prediktora od samih demografskih obilježja. Posjedovanje automobila i zamrzivača snažni su pozitivni prediktori inflacije, što reflektira cjenovne šokove u segmentu energenata. Zamrzivač, iako alat za optimizaciju kupnje na sniženjima, u uvjetima skupe električne energije postaje financijski teret, posebno ako je riječ o uređajima starije generacije. Nasuprot tome, kućanstva s višim standardom (npr. s klima-uređajima) pokazuju veću otpornost zbog diverzificiranije košarice.

Ekonomske politike trebale bi prepoznati heterogenost unutar najnižih dohodovnih skupina. Uz dohodovni cenzus, pomoć treba usmjeriti

prema jednočlanim umirovljeničkim i višečlanim kućanstvima s niskim dohotkom. Dugoročno, otpornost bi ojačale mjere poticanja zamjene energetski neučinkovitih uređaja te poboljšanje transportne povezanosti u područjima gdje je automobil nužnost. Veća progresivnost postigla bi se fokusiranjem sredstava na ugrožene, umjesto univerzalnih subvencija koje pogoduju onima s većom ukupnom potrošnjom.

Zaključno, rad nadograđuje istraživanja Rubila i sur. (2024) potvrđujući da dohodovni gradijent i energetska ovisnost ostaju konstante nejednakosti. Buduća istraživanja trebala bi istražiti dinamiku supstitucije unutar COICOP kategorija koristeći podatke o cijenama u realnom vremenu te analizirati kako se heterogenost u cjenovnoj osjetljivosti prenosi na inflacijska očekivanja kućanstava, što bi omogućilo još preciznije predviđanje distributivnih učinaka budućih cjenovnih šokova.

Literatura

Aguiar, M. i Hurst, E. (2007). Life-cycle prices and production. American Economic Review, 97(5), 1533-1559.

Arčabić, V. (2025). Priča o dvije inflacije u Hrvatskoj: uloga domaćih i inozemnih šokova. EFZG working paper series, 2025(04), 1-22.

Caplovitz, D. (2025). The poor pay more: Consumer practices of low-income families. Bonhopai Books.

Cavallo, A. (2017). Are online and offline prices similar? Evidence from large multi-channel retailers. American Economic Review, 107(1), 282-303.

Cavallo, A. (2024). Inflation with Covid consumption baskets. IMF Economic Review, 72(2), 902-917.

Cavallo, A. i Kryvtsov, O. (2024). Price discounts and cheapflation during the post-pandemic inflation surge. Journal of Monetary Economics, 148, 103644.

Charalambakis, E., Fagandini, B., Henkel, L. i Osbat, C. (2022). The impact of the recent rise in inflation on low-income households. Economic Bulletin Boxes, European Central Bank, vol.7.

Chen, T., Levell, P. i O'Connell, M. (2024). Cheapflation and the rise of inflation inequality. CEPR Discussion Papers, 1, 22.

D'Acunto, F., Malmendier, U. i Weber, M. (2021). Gender roles produce divergent economic expectations. Proceedings of the National Academy of Sciences, 118(21).

D'Acunto, F., Malmendier, U. i Weber, M. (2023). What do the data tell us about inflation expectations?. U R. Bachmann, G. Topa, i W. van der Klaauw (Ur.), Handbook of Economic Expectations (str. 133-161). Academic Press.

Falagiarda, M., Gartner, C., Mužić, I. i Pufnik, A. (2023). Has the euro changeover really caused extra inflation in Croatia?. European Central Bank, dostupno na: https://www.ecb. europa. eu/press/blog/date/2023/html/ecb. blog.

Gerarden, T. D., Newell, R. G. i Stavins, R. N. (2017). Assessing the energy-efficiency gap. Journal of economic literature, 55(4), 1486-1525.

Gürer, E. i Weichenrieder, A. (2020). Pro-rich inflation in Europe: Implications for the measurement of inequality. German Economic Review, 21(1), 107-138.

Handbury, J. (2021). Are poor cities cheap for everyone? Non-homotheticity and the cost of living across US Cities. Econometrica, 89(6), 2679-2715 .

Hrvatska narodna banka. (2025). Makroekonomske projekcije za Hrvatsku (lipanj 2025).

Jaravel, X. (2021). Inflation inequality: Measurement, causes, and policy implications. Annual Review of Economics, 13, 599-629.

Jevons, W. S. (1874). The mathematical theory of political economy. Journal of the Royal Statistical Society Series A: Statistics in Society, 37(4), 478-488.

Kaplan, G. i Schülhofer-Wohl, S. (2017). Inflation at the household level. Journal of Monetary Economics, 91, 19-38 .

Mullainathan, S. i Spiess, J. (2017). Machine learning: an applied econometric approach. Journal of Economic Perspectives, 31(2), 87-106.

Orhun, A. Y. i Palazzolo, M. (2019). Frugality is hard to afford. Journal of Marketing Research, 56(1), 1-17.

Rubil, I., Tkalec, M. i Žilić, I. (2024). Nejednakosti inflacije u Hrvatskoj. Revija za socijalnu politiku, 31(1), 1-27.

Wehrhöfer, N. (2023). Energy prices and inflation expectations: Evidence from households and firms. Deutsche Bundesbank, No. 28/2023.

Inflation Inequality and its Structural Determinants: A Microdata Level Analysis

Abstract

The paper analyses the determinants of inflation inequality in Croatia (2019–2025) using microdata from the Household Budget Survey. A pooled repeated cross-sections regression and the LASSO method were used to identify socioeconomic characteristics that predict exposure to price increases. What stands out in our analysis is how income levels fundamentally dictate the way inflation hits different citizens. The heavy burden on lower-income groups stems directly from the structural inelasticity of their spending; when your budget is tied up in essentials like food and heat, there is simply no room to switch to cheaper alternatives. Looking closer at the bottom income decile, the data shows that singles and large families are in a much tougher spot, while age plays a surprisingly small role. Our LASSO results also point to a link between physical assets and inflation rates. Interestingly, having a car or a freezer makes a household more vulnerable to energy shocks, yet higher housing standards and air conditioning somehow act as a buffer. Ultimately, the takeaway is clear: anti-inflation measures need to be progressive and tightly focused on energy-vulnerable and specific demographic groups.

Keywords: inflation inequality, households inflation, Croatia, consumption heterogeneity, LASSO regression.