Maastricht University

Maastricht Graduate School of Governance

NOVI METODI CILJANJA ZA BOSNU I HERCEGOVINU

Prvi dio

Septembar, 2013

Sadržaj

1 Uvod 6

2 Metodologija 8

2.1 Podaci 8
2.2 Indikator blagostanja 8
2.3 Odabir ciljnih grupa 9
2.4 Prezentacija i tumačenje rezultata 14
2.5 Referentna vrijednost 15

3 Modeli indirektnog imovinskog cenzusa 19

3.1 Replikacija modela iz 2007. godine 19
3.2 Novi modeli indirektnog imovinskog cenzusa 23
3.3 Postojeći prihodovni testovi s dodatnim filterima 27

4 Kategorijsko ciljanje 30

5 Hibridne i druge metode ciljanja 33

5.1 Indirektni imovinski cenzus sa prihodima 33
5.2 Indirektni imovinski cenzus nakon filtera 34
5.3 Izdaci za komunalije 38

6 Pregled rezultata i odabir modela za dalje simulacije 41

7 Zaključci i preporuke za politike 48

7.1 Postizanje ravnoteže između djelotvornosti i unapređenja efikasnosti 48
7.2 Implementacija novih modela 49
7.3 Naredni koraci 49

Reference 50

Dodatak 51

Spisak tabela

Tabela 1. Obuhvat naknada za budžetske novčane naknade, FBiH, 2011. 17
Tabela 2. Distribucija korisnika budžetskih novčanih naknada u FBiH, u %, 2011. 17
Tabela 3. Distribucija budžetskih novčanih naknada u FBiH, u %, 2011. 17
Tabela 4. Obuhvat naknada za budžetske novčane naknade, RS, u%, 2011. 18
Tabela 5. Distribucija korisnika budžetskih novčanih naknada u RS, u %, 2011. 18
Tabela 6. Distribucija budžetskih novčanih naknada u RS, u %, 2011. 18
Tabela 7 Obuhvat i distribucija korisnika po modelu indirektnog imovinskog cenzusa iz 2007 (po podacima iz 2011.), za različit obim programa, po kvantilama potrošnje po osobi nakon transfera, FBiH 21
Tabela 8. Obuhvat i distribucija korisnika modela indirektnog imovinskog cenzusa iz 2007. godine (sa podacima za 2011.), različiti obimi programa, po kvantilama za potrošnju po ekvivalentu odrasle osobe (skala OECD 1), prije transfera, za FBiH 21
Tabela 9. Obuhvat i distribucija korisnika modela indirektnog imovinskog cenzusa iz 2007 (sa podacima za 2011.), različiti obimi programa, po kvantilama potrošnje po stanovniku nakon transfera, u RS. 22
Tabela 10. Obuhvat i distribucija korisnika modela indirektnog imovinskog cenzusa iz 2007. godine (sa podacima za 2011. godinu, različiti obimi programa, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS ... 22
Tabela 11. Obuhvat i distribucija korisnika novokalibriranog modela indirektnog imovinskog cenzusa zasnovanog na cjelokupnoj populaciji (sa podacima iz 2011.), različitim obimom programa, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za FBiH..... 25
Tabela 12 Obuhvat i distribucija korisnika novokalibriranog modela indirektnog imovinskog cenzusa zasnovanog na odvojenim ruralnim/urbanim područjima (s podacima za 2011.), različitim obimom programa, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1), prije transfera, za FBiH 25
Tabela 13. Obuhvat i distribucija korisnika novokalibriranog modela indirektnog imovinskog cenzusa zasnovanog na cjelokupnoj populaciji (sa podacima iz 2011.), različitim obimom programa, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS 26
Tabela 14. Obuhvat i distribucija korisnika novokalibriranog modela indirektnog imovinskog cenzusa zasnovanog na odvojenim ruralnim/urbanim područjima (s podacima za 2011.), različitim obimom programa, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1), prije transfera, za RS 26
Tabela 15. Obuhvat i distribucija korisnika, kao i distribucija naknada, uz primjenu dodatnih filtera povrh prihodovnog cenzusa koji se sada primjenjuje, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za FBiH 28
Tabela 16. Obuhvat i distribucija korisnika, kao i distribucija naknada, uz primjenu dodatnih filtera povrh prihodovnog cenzusa koji se sada primjenjuje, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS. .. 29
Tabela 17. Obuhvat i distribucija korisnika primjenom kategorijskog ciljanja, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OEC 1) prije transfera, za FBiH... 31
Tabela 18. Obuhvat i distribucija korisnika primjenom kategorijskog ciljanja, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS ... 32
Tabela 19. Obuhvat i distribucija korisnika novokalibriranog modela indirektnog imovinskog cenzusa koji uključuje prihode iz provjerljivih izvora, zasnovani na odvajanju ruralnih i urbanih područja (sa podacima iz 2011.), različiti obim programa, po

kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1), prije transfer, za FBiH 33
Tabela 20. Obuhvat i distribucija korisnika ruralnog/urbanog modela indirektnog imovinskog cenzusa nakon primjene različitih filtera, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za FBiH, obim programa od 10%. 35
Tabela 21. Obuhvat i distribucija korisnika ruralnog/urbanog modela indirektnog imovinskog cenzusa nakon primjene različitih filtera, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za FBiH, obim programa od 15% 35
Tabela 22. Obuhvat i distribucija korisnika ruralnog/urbanog modela indirektnog imovinskog cenzusa nakon primjene različitih filtera, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za FBiH, obim programa od 20% 36
Tabela 23. Obuhvat i distribucija korisnika ruralnog/urbanog modela indirektnog imovinskog cenzusa nakon primjene različitih filtera, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS, obim programa od 10% ... 36
Tabela 24. Obuhvat i distribucija korisnika ruralnog/urbanog modela indirektnog imovinskog cenzusa nakon primjene različitih filtera, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS, obim programa od 15% ... 37
Tabela 25. Obuhvat i distribucija korisnika ruralnog/urbanog modela indirektnog imovinskog cenzusa nakon primjene različitih filtera, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS, obim programa od 20% ... 37
Tabela 26. Eliminatorne vrijednosti (u KM) na osnovi procijenjenih prosječnih mjesečnih izdataka za električnu energiju za 2011, različiti obim programa, za FBiH i RS ... 38
Tabela 27. Obuhvat i distribucija za ciljanje na osnovi procijenjenih prosječnih mjesečnih izdataka za električnu energiju, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1), prije transfera, za FBiH..... 39
Tabela 28. Obuhvat i distribucija za ciljanje na osnovi procijenjenih prosječnih mjesečnih izdataka za električnu energiju, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1), prije transfera, za RS..... 39
Tabela 29. Pregled efikasnosti/učinkovitosti ciljanja simuliranih modela, za FBiH..... 43
Tabela 30. Pregled efikasnosti/učinkovitosti ciljanja simuliranih modela, za RS..... 43

Tabela A 1. Replikacija modela indirektnog imovinskog cenzusa iz 2007. godine sa podacima iz 2011. godine..... 51
Tabela A 2. Modeli potrošnje zasnovani na cjelokupnoj populaciji, ruralna i urbana područja, za FBiH 53
Tabela A 3. Modeli potrošnje zasnovani na cjelokupnoj populaciji, ruralnim i urbanim područjima, za RS 56
Tabela A 4. Indirektni imovinski cenzus uz uključenje prihoda, za ruralna područja FBiH.... 59
Tabela A 5. Obuhvat i distribucija ciljanja zasnovana na izdacima za električnu energiju, vodovod i kanalizaciju, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za FBiH 61
Tabela A 6. Obuhvat i distribucija ciljanja zasnovana na izdacima za električnu energiju, vodovod i kanalizaciju, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS 61
Tabela A 7. Spisak svih varijabli koje su inicijalno bile uključene u proces ocjenjivanja novokalibriranih modela indirektnog imovinskog cenzusa, cjelokupna populacija kao i urbani/ruralni modeli, FBiH i RS 62

Spisak grafikona

Grafikon 1. Kompromis između greške isključenja i greške uključenja kada se cilja najsiromašnijih 20% populacije primjenom dodatnih filtera povrh prihodovnog cenzusa koji je trenutno u upotrebi, za FBiH 44
Grafikon 2. Kompromis između greške isključenja i greške uključenja kada se cilja najsiromašnijih 20% populacije primjenom dodatnih filtera povrh prihodovnog cenzusa koji je trenutno u upotrebi, za RS 44
Grafikon 3. Kompromis između greške isključenja i greške uključenja kad se cilja najsiromašnijih 20% populacije primjenom kategorijskog ciljanja, za FBiH 45
Grafikon 4. Kompromis između grešaka isključenja i uključenja kada se cilja najsiromašnijih 20% populacije uz korištenje kategorijskog ciljanja, za RS 45
Grafikon 5. Greška uključenja i isključenja kad se primjenjuju filteri povrh urbanog/ruralnog modela indirektnog imovinskog cenzusa, obim programa polazne osnove: 10%, za FBiH 46
Grafikon 6. Greška uključenja i isključenja kad se primjenjuju filteri povrh urbanog/ruralnog modela indirektnog imovinskog cenzusa, obim programa polazne osnove: 10%, za RS 46
Grafikon 7. Greška uključenja i isključenja kad se primjenjuju filteri povrh urbanog/ruralnog modela indirektnog imovinskog cenzusa, obim programa polazne osnove: 20%, za FBiH 47
Grafikon 8. Greška uključenja i isključenja kad se primjenjuju filteri povrh urbanog/ruralnog modela indirektnog imovinskog cenzusa, obim programa polazne osnove: 20%, za RS 47

Grafikon A 1**.** Odnos između izdataka na električnu energiju i potrošnje, 2011, za FBiH i RS 65
Grafikon A 2. Mjesečne varijacije u prijavljenim izdacima za električnu energiju (u KM), za FBiH i RS 65

1 Uvod

Cilj ovog izvještaja je da se analiziraju mogućnosti alternativnih metoda ciljanja za budžetske naknade namijenjene opštoj populaciji u Bosni i Hercegovini, s krajnjim ciljem da se poboljša kvalitet ciljanja i učinak na smanjenje siromaštva ovakvih socijalnih transfera. Bosna i Hercegovina je jedna od zemalja u regionu Evrope i Centralne Azije koje najviše troše na socijalnu zaštitu. Između 2006. i 2008. godine, za socijalne transfere bilo je namijenjeno četiri posto BDP. U prošlosti je znatan dio ovih transfera odobravan na osnovi stečenih prava a ne aktuelnih potreba. Analiza sadašnje situacije u Bosni i Hercegovini ukazuje na potrebu da se ciljanje budžetskih naknada namijenjenih opštoj populaciji poboljša i da se tako ojača njihov učinak na smanjenje siromaštva.

Ovaj izvještaj se poziva na Bilješku o politikama Svjetske banke "*Social Assistance Transfers in Bosnia and Herzegovina: Moving Toward a More Sustainable and Better-Targeted Safety Net" (Socijalna davanja u Bosni i Hercegovini: Kreiranje održivog sistema socijalne zaštite zasnovanog na stvarnim potrebama)* iz 2009. godine. Ova bilješka je urađena da se analiziraju postojeća davanja za socijalnu zaštitu u BiH koja nisu zasnovana na principu osiguranja i da se razradi mehanizam indirektnog imovinskog cenzusa zasnovan na Anketi o potrošnji domaćinstava iz 2007. godine. Kao zaključak, ona preporučuje pristup sa tri aspekta, koji bi obuhvatio mjere kao što su (a) poboljšanje i uvođenje mehanizama ciljanja radi boljeg usmjeravanja sredstava siromašnima, (b) jačanje mehanizama administriranja naknada i sistema registracije korisnika i (c) fokus na racionalizaciju sistema invalidskih naknada. Ovaj izvještaj se usredsređuje na prvi od aspekata ovog pristupa i tehnički razrađuje poboljšane mehanizme ciljanja.

U ovom izvještaju razmatraju se alternativni mehanizmi ciljanja za Bosnu i Hercegovinu.[1] Unaprijedili smo ranije kalibrirani model indirektnog imovinskog cenzusa koristeći najsvježije dostupne podatke iz ankete o potrošnji stanovništva iz 2011. Sama analiza nije ograničena na razradu ažurirane formule indirektnog imovinskog cenzusa, već se širi na razmatranje alternativnih mehanizama ciljanja, uključujući unošenje provjerljivih izvora prihoda u modele indirektnog imovinskog cenzusa, primjenu dodatnih flitera na postojeće mehanizme prihodovnog cenzusa, jedan mehanizam zasnovan na troškovima za komunalije, te ciljanje po kategorijama.

Izvještaj se usto veže i sa još dvije studije koje su rađene u okviru projekta *"Razvoj, testiranje i primjena nove metodologije/a ciljanja budžetskih naknada u BiH" (Development, testing and implementation of new methodology(ies) for targeting of non-contributory benefits in Bosnia and Herzegovina").* S jedne strane, u prvom dijelu izvještaja "Budžetske novčane naknade za socijalnu zaštitu u BiH – Šta funkcioniše, a šta ne" (*Non-contributory cash benefits for Social Protection in Bosnia and Herzegovina – What works and what does not)* daje se pregled i analiza postojećih zakona i propisa o budžetskim naknadama u Federaciji Bosne i Hercegovine (FBiH) i Republici Srpskoj (RS). Usto se razmatraju i fiskalni aspekti i posljedice ovih davanja. On je prema tome koristan referentni materijal za detaljniji opis trenutno postojećih budžetskih novčanih transfera. U drugom dijelu razrađuju se mehanizmi ciljanja, kako sa više teoretske tačke gledišta, uz razmatranje njegove logičke podloge, metoda i ocjene efikasnosti/učinkovitosti ciljanja i daju se primjeri iz zemalja u regionu Evrope i

[1] Molimo pogledati izvještaj „Ciljanje budžetskih novčanih transfera – Teorija i dokazi u odabranim državama" (Targeting of non-contributory cash transfers – Theory and evidence from selected countries) koji izlaže šira teorijska razmatranja o različitim mehanizmima ciljanja, mjerenjima efekata ciljanja i primjere iz drugih zemalja Evrope, Centralne Azije i Južne Amerike.

Centralne Azije (ECA) i šire. S druge strane, studija *"Siromaštvo u BiH 2011 – Trendovi i dostignuća i Indikatori adekvatnosti ciljanja budžetskih transfera za socijalnu zaštitu u BiH 2011"* (Poverty in BiH 2011 – Trends and achievements and Indicators of the Targeting Accuracy of Budgets Transfers for Social Protection in BiH in 2011), prezentira, na temelju podataka Ankete o potrošnji domaćinstava iz 2011, profil siromaštva za dva entiteta i nudi indikatore efikasnosti/učinkovitosti ciljanja budžetskih novčanih transfera.

Ovaj izvještaj pripremio je tim Postdiplomske škole za upravu iz Maastrichta (Maastricht Graduate School of Governance), u sastavu: Franziska Gassmann (vođa tima), Mira Bierbaum, Daphne Francois i Eli Stojkova.

2 Metodologija

U odjeljku o metodologiji prvo se ukratko opisuje skup podataka koji se koristio za mjere efikasnosti postojećih budžetskih novčanih transfera i razradu alternativnih mehanizama ciljanja, nakon čega slijedi opis glavnog indikatora blagostanja. U njemu se još ukratko opisuje odabir kvalifikovanih grupa i način na koji se rezultati prezentiraju i kako se tumače. I naposlijetku, odjeljak se završava pregledom efikasnosti/učinkovitosti ciljanja budžetskih novčanih naknada u sadašnjem sistemu, koji služi kao referentna vrijednost za sve alternativne mehanizme ciljanja.

2.1 Podaci

Anketa o potrošnji domaćinstava (APD) iz 2011. je glavna alatka za mjerenje siromaštva i praćenje životnog standarda u BiH. Ona prikuplja informacije o, između ostalog, prihodima i potrošnji, socioekonomskim karakteristikama članova domaćinstva, stambenim uslovima, posjedovanju trajnih roba, te o penzijama i socijalnim naknadama

Strategija uzorkovanja APD je dvostepeno sistematsko uzorkovanje. Prvo je izvučen sistematski uzorak oko 1500 popisnih krugova iz ukupnog broja od oko 20.000 popisnih krugova popisa iz 1991. godine. Ovo je dovelo do spiska od oko 81.000 domaćinstava. U drugom stepenu, sa ovog spiska izvučen je sistematski uzorak od 9,700 domaćinstava. Uz stopu neodgovora od 24%, konačni broj intervjuisanih domaćinstava bio je 7.400 (4.611 u Federaciji Bosne i Hercegovine (FBiH), 2.437 u Republici Srpskoj (RS) i 352 u Distriktu Brčko.

APD 2011. je sprovedena između 1. januara i 31. decembra 2011. Intervjui su vođeni licem u lice, a obavljene su najmanje tri posjete svakom domaćinstvu: prilikom prvog susreta, domaćinstvo je dobilo dnevnik potrošnje za 15 dana. Druga posjeta se obavljala nakon tri do četiri dana, a finalni intervju se vodio nakon 15 dana.

2.2 Indikator blagostanja

U skladu sa uobičajenom praksom u BiH, glavni indikator blagostanja je ukupna mjesečna potrošnja domaćinstva. Ukupna potrošnja u APD obuhvata slijedeće stavke: hranu i piće; alkoholna pića i duhan; odjeću i obuću; stan, električnu energiju, plin vodu i druge komunalije; namještaj, opremu i održavanje; zdravstvenu zaštitu; transport, komunikacije, rekreaciju i kulturu; obrazovanje, hotele i restorane i druge proizvode i usluge. Nedostatak se pojavljuje zbog činjenice da se anketa vodi tokom čitave godine, tako da se za različita domaćinstva potrošnja mjeri u različitim mjesecima, što možda dovodi do uključivanja sezonskih efekata (Svjetska banka, 2009b, str. 32). Agregat potrošnje se izražava u nominalnim cijenama iz 2011. godine. Pošto ovaj agregat nije korigovan za regionalne razlike u cijenama na entitetskom nivou, svi modeli se procjenjuju odvojeno za FBiH i RS.

Za analizu novih mehanizama ciljanja budžetskih transfera za civilno stanovništvo, varijabla koja nas u stvari zanima nije nivo blagostanja koji se postigne nakon transfera budžetskih novčanih naknada za civilno stanovništvo, već nivo blagostanje koji bismo uočili da domaćinstvo nije dobilo nijedan od tih transfera. Očito je da se ovaj izvedeni nivo blagostanja ne može uočiti u stvarnosti (jer domaćinstva u stvarnosti dobijaju transfere koji poboljšavaju njihov životni standard, odnosno podižu nivo blagostanja – *op. prevodioca*). Usvojili smo

metodologiju koji je predložio Tesliuc (2004.) za modeliranje bihevioralne reakcije domaćinstva na na javne socijalne transfere. Pretpostavka je da domaćinstva prilagođavaju svoje ponašanje i da određen dio socijalnih transfera, u odsustvu tih transfera, zamjenjuju npr. pronalaženjem još jednog zaposlenja, bavljenjem primitivnom zemljoradnjom ili preseljenjem.

U ovu svrhu, razradili smo nekoliko modela potrošnje sa potrošnjom po osobi (ili po ekvivalentu odrasle osobe, primjenom skale OECD 1, vidi u daljem tekstu) kao zavisnom varijablom. Nezavisne varijable su razne karakteristike domaćinstava, a prihod od socijalnih transfera kao dodatna opisna varijabla. Koeficijent ove varijable pokazuje za koliko KM po osobi/ekvivalentu odrasle osobe se potrošnja povećava ako se dati socijalni transfer poveća za 1 KM. Na osnovi niza modela (sa ili bez kontroliranja prema sastavu domaćinstva, lokaciji (urbano/ruralno) i karakteristici nosioca domaćinstva), odlučeno je da se uzima da je granična sklonost potrošnji 33% socijalnih transfera.

Štaviše, ukupna potrošnja domaćinstva prije transfera naknada za civilno stanovništvo prilagođava se po skali ekvivalentnosti OECD 1. Nasuprot pristupu po osobi, skala ekvivalentnosti OECD 1 ne dodjeljuje svakom članu porodice jednak ponder, već raspoređuje slijedeće pondere: 1 za nosioca domaćinstva, 0,7 za svakog dodatnog člana domaćinstva starosti 14 ili više godina i 0,5 za svako dijete starosti ispod 14 godina. Logička podloga za korištenje skala ekvivalentnosti je koncept da potrebe domaćinstava za potrošnjom rastu sa svakim dodatnim članom domaćinstva, ali ne direktno proporcionalno. Veća domaćinstva imaju koristi od ekonomije obima pošto, npr. domaćinstvo od tri člana neće koristiti tri puta više električne energije, ili stambenog prostora, kao domaćinstvo od jedne osobe (Förster & d'Ercole, n.d.)

Uobičajena praksa kod poređenja siromaštva u Evropskoj uniji je da se primjenjuje skala ekvivalencije OECD 2, po kojoj se prvoj odrasloj osobi dodjeljuje ponder vrijednosti 1, svakom slijedećem odraslom članu domaćinstva 0,5 a djeci mlađoj od 14 godina ponder 0,3. Primjena skale OECD 2 u slučaju BiH, gdje se – posebno u siromašnim domaćinstvima – na hranu troši relativno velik udio potrošnje domaćinstva, vjerojatno bi dovela do potcjenjivanja potreba za potrošnjom dodatnih članova domaćinstva.

U zaključku, ako se drugačije ne naglasi u odgovarajućem odjeljku, analize se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije transfera budžetskih novčanih naknada za civilno stanovništvo, uz pretpostavku da je granična sklonost potrošnji iz ovih socijalnih transfera 33%.

2.3 Odabir ciljnih grupa

Ovaj izvještaj opisuje niz mehanizama za odabir kvalifikovanih korisnika. To su:

- indirektni imovinski cenzus;
- dodatni filteri za postojeće prihodovne cenzuse;
- kategorijsko ciljanje;
- ostali/hibridni oblici ciljanja, tj. indirektni imovinski cenzus sa verifikovanim prihodima i ciljanje zasnovano na rashodima za komunalije.

Indirektni imovinski cenzus

Indirektni imovinski cenzus je način procjene blagostanja domaćinstva u zemljama gdje su ekonomske aktivnosti u velikom stepenu neregistrovane a vjerovatno je da prihodi od formalnog zaposlenja, kao što su plate, ne odražavaju precizno blagostanje domaćinstava. Logička podloga za indirektni imovinski cenzus je da se pronađe alternativni pokazatelj nivoa blagostanja domaćinstava koji se može upotrijebiti za identifikaciju korisnika. Izlazni rezultat za svako prijavljeno domaćinstvo ili pojedinca računa se na temelju lako uočljivih karakteristika koje su povezane sa nivoom blagostanja domaćinstva, kao što su lokacija i kvalitet stambenog prostora, sastav domaćinstva, obrazovanje i zanimanje nosioca domaćinstva i posjedovanje trajnih dobara.

Za pronalaženje indikatora koji su najtješnje povezani sa nivoom blagostanja domaćinstva, koristi se stepenovani obični regresioni model najmanjih kvadrata (stepwise OLS regression model). Počinjući od opsežne liste potencijalnih veza sa potrošnjom, nakon svake iteracije regresionog modela nezavisna varijabla sa najmanjim nivoom statističkog značajnosti (tj. s najvećom vrijednosti "p"/najmanjom vrijednosti "t") se isključuje iz modela sve dok sve preostale varijable nisu značajne na nivou 10%. Procijenjeni model može se predstaviti ovako:

$$\ln(y_i) = \alpha + \beta X_i + \varepsilon_i ,$$

pri čemu je $\ln(y_i)$ prirodni logaritam potrošnje po ekvivalentu jedne odrasle osobe (skala OECD 1) prije transfera[2], α je konstanta, β je vektor koeficijenata, X_i je vektor domaćinstva i karakteristika domaćinstva, a ε_i je stohastički član. Prirodni logaritam ovog indikatora koristi se pošto je njegova distribucija izrazito asimetrična udesno, što može rezultirati pristranim procjenama. Ponderi za uzorkovanje na individualnom nivou se primjenjuju da se uzorak učini reprezentativnim za cijelu populaciju.

Uprkos normativnoj odluci da se uključe varijable sa nivoom značajnosti od do 10%, najveći broj varijabli obuhvaćenih procijenjenim modelima značajni su na nivou od 1%. Prema tome, odabir restriktivnijeg nivoa eliminacije (npr. nivoa od 1% značajnosti) da bi se dobili efikasniji modeli bi samo marginalno umanjilo broj obuhvaćenih indikatora.

Spisak potencijalnih indikatora sastavljen je po iskustvima drugih zemalja i na osnovu raspoloživih podataka iz APD 2011. Osim što treba da koreliraju sa nivoom blagostanja domaćinstava, indikatori treba da budu lako uočljivi i provjerljivi, a istovremeno treba da budu teški za manipulaciju da bi se izbjegle prevare.

Prvo se razmatra skup *karakteristika domaćinstva*, koji između ostalog obuhvata prirodni logaritam veličine domaćinstva, broja djece, starih, penzionera i zaposlenih članova domaćinstva, kao i najviši dosegnuti nivo obrazovanja u domaćinstvu. Ovaj skup varijabli takođe obuhvata i karakteristike nosioca domaćinstva, kao što su rod, nivo obrazovanja ili ekonomski status (zaposlen na stalnom ugovoru, zaposlen s drugim tipovima ugovora, nezaposlen, penzioner, neaktivan). Primjer djece ilustruje da ponekad postoje različiti načini na koji se neka varijabla može definisati: na primjer, možemo pitati da li dato domaćinstvo ima dijete mlađe od šest godina (tj. uključenje binarne varijable koja prima vrijednost 1 kada postoji dijete mlađe od 6 godina u domaćinstvu odnosno vrijednost 0 kada dijete mlađe od 6 godina ne postoji u domaćinstvu) ili broj djece mlađe od šest godina koja žive u datom domaćinstvu (što znači da bi ovaj podatak bio uključen kao prirodan broj 0, 1, 2, 3 itd. prema

[2] Sve analize su vršene i za mjesečnu potrošnju po osobi prije transfera. Rezultati se mogu dostaviti na zahtjev.

broju djece mlađe od 6 godina u domaćinstvu). Možemo posmatrati i svu djecu mlađu od 18 godina, ili praviti razliku između predškolske (mlađe od šest godina) i školske djece (6-17 godina). Ako je bilo primjenljivo, isprobali smo različite načine definisanja varijabli da bismo pronašli najprikladniji način da ih uključimo u model indirektnog imovinskog cenzusa.

Druga grupa indikatora govori o *karakteristikama stana*. Ove karakteristike, između ostalih, obuhvataju vrstu stana i njegov pravni status (iznajmljen ili u vlasništvu), broj osoba po jednoj sobi, da li domaćinstvo ima odvojenu kuhinju, kupatilo, toplu vodu, električnu energiju, grijanje, telefonsku liniju itd. ili da li domaćinstvo ima sekundarni stambeni prostor. Treće, uključili smo vještačke varijable za *posjedovanje trajnih dobara*, npr. kuhala, peći, hladnjaka, mašine za pranje veša, mašine za pranje posuđa, satelitske antene. Posljednji skup indikatora pokazuje da li bar jedan član u domaćinstvu ima prihod od penzije ili veteransku naknadu, ima zvanično rješenje o invalidnosti, kao i logaritam mjesečnih troškova za komunalije (električna energija, plin, centralno grijanje, vodovod/kanalizacija i odvoz smeća).

Uzimajući u obzir entitetski specifične razlike u uslovima života, modeli indirektnog imovinskog cenzusa su razrađivani odvojeno za FBiH i RS. Rezultirajući koeficijenti modela korišteni su da se predvidi potrošnja svakog od domaćinstava u uzorku. Nakon toga, ovim predviđanjima identifikovani su kvalifikovani pojedinci primjenom tri različita praga kvalifikovanosti (najsiromašnijih 10, 15 ili 20% populacije).

Povrh toga, za svaki entitet takođe smo razradili odvojene modele za urbana i ruralna područja da bismo uzeli u obzir različite uslove života. Urbani/ruralni modeli izračunati su na osnovi dva odvojena regresiona modela - jedan model je razvijen za populaciju u ruralnim područjima, a poseban za urbanu populaciju. Drugim riječima, koristili smo dvije različite formule za predviđanje potrošnje, jednu za urbana, a drugu za ruralna područja. U ovom slučaju, da bismo simulirali efikasnost/učinkovitost ciljanja na cijeloj populaciji, kombinovali smo predviđanja potrošnje za urbanu i ruralnu populaciju i onda primijenili pragove da bismo dobili rezultate u smislu obuhvata i distribucije. Ovi modeli se u daljem tekstu nazivaju “urbani/ruralni modeli” indirektnog imovinskog cenzusa.

Dodatni filteri povrh postojećeg prihodovnog cenzusa

Potencijal za dodatno poboljšanje efikasnosti/učinkovitosti ciljanja postojećeg prihodovnog cenzusa je simuliran uz primjenu dodatnih filtera povrh prihodovnog cenzusa koji se trenutno primjenjuje. To znači da se dato domaćinstvo kvalifikuje ako (1) trenutno prima budžetsku novčanu naknadu za civilno stanovništvo i (2) za nju ne važi neko od filter-pitanja, pr. da li dato domaćinstvo posjeduje (nov) automobil, ima internet konekciju, garažu itd. Odabir odgovarajućih filtera dijelom je vršen na osnovu uvida iz modela indirektnog imovinskog cenzusa, koji ukazuju koje su karakteristike stana ili trajnih potrošačkih dobara povezane sa višim nivoom blagostanja datog domaćinstva.

Kategorijsko ciljanje

Kategorijsko ili grupno ciljanje identifikuje korisnike na osnovi individualnih ili karakteristika domaćinstva koje su lako uočljive, teške za manipulaciju i koje su u korelaciji sa nižim nivoom blagostanja. Na odabir ovih kategorija utjecale su informacije iz profila siromaštva kao i iz modela indirektnog imovinskog cenzusa.

Indirektni imovinski cenzus sa verifikovanim prihodima

Iako indirektni imovinski cenzus u principu zamjenjuje potrebu da se verifikuju prihodi domaćinstva, u BiH je moguće pouzdano verifikovati neke izvore prihoda. Na primjer, model

indirektnog imovinskog cenzusa koji obuhvata prihode za ciljanje naknada socijalne zaštite je uspješno uveden u Gruziji, gdje je bilo jednako teško verifikovati prihode zbog visokog stepena sive ekonomije.[3] Stoga smo razvili jedan hibridni model koji uključuje prihod iz provjerljivih izvora u model indirektnog imovinskog cenzusa i analizira da li se time poboljšala prediktivna moć datog modela indirektnog imovinskog cenzusa, a shodno tome i efikasnost/učinkovitost ciljanja.

APD iz 2011. obuhvata pitanja o prihodima od zaposlenja, imovine itd. za sve anketirane starije od 14 godina. Na osnovi intervjua obavljenih u tri centra za socijalni rad (CSR) u Novom Sarajevu, Trebinju i Trnovu, identifikovani su slijedeći izvori prihoda koje je moguće provjeriti i u FBiH i u RS:

- plate zaposlenih koji rade za lokalnog poslodavca (A1)
- plate zaposlenih koji rade za stranog poslodavca (A2)
- topli obrok (isključujući bonove i obroke) (A7)
- naknade za prijevoz na i sa radnog mjesta (isključujući bonove) (A8)
- naknade za odvojeni život (A9)
- honorari za članove upravnih/nadzornih odbora (A10)
- ostali novčani prihodi od zaposlenja (regres, bonusi, otpremnina, zimnica, ogrjev, naknada tokom bolovanja ili jednokratna pomoć u slučaju smrti) (A11)
- prihod od zaposlenja u naturi (uključujući obroke i prijevoz) (A12)
- zarada od rada u vlastitom preduzeću (A13).

Na odabir izvora prihoda koji se uključuju u model indirektnog imovinskog cenzusa dodatno utječu i slijedeći faktori: Prvo, uzimaju se u obzir samo novčani prihodi, tj. prihodi od zaposlenja u naturi, kao što su obroci i prijevoz (A12) se ne uključuju. Drugo, uzimaju se u obzir samo prihodi koji se primaju redovno. Iz ovog slijedi da su isključeni prihodi od honorara za članove upravnih ili nadzornih odbora (A10) i drugi gotovinski prihodi od zaposlenja (A11). Treće, pošto svaki dodatni izvor prihoda koji se uključuje uzrokuje dodatne administrativne napore i troškove, odlučeno je da se ne razmatraju izvori prihoda koji važe samo za veoma malu grupu ljudi. To je slučaj sa naknadama za odvojen život (A9), koje se dodjeljuju samo veoma rijetko.

Četvrto, provjera zarada iz rada za vlastito preduzeće još se ocjenjuje kao izuzetno teška, uz mogućnost da se ovi prihodi prijavljuju u znatno manjim iznosima. Zbog toga nisu uključeni u niže opisane modele. I napokon, topli obrok (A7) i naknada za prijevoz (A8) obično primaju samo ljudi koji primaju platu od lokalnih ili stranih poslodavaca (A1 ili A2). Za relativno mali broj ljudi koji prijavljuju ove izvore prihoda a da nisu zaposleni, upitno je u kojoj mjeri se može provjeriti primanje ovih prihoda. Zbog toga su glavni izvori prihoda koji su zanimljivi za hibridne modele plate zaposlenih koji rade za lokalne ili strane poslodavce (A1 ili A2). U slučaju da ovi zaposleni primaju dodatni topli obrok ili naknadu za transport povrh svojih plata, i ovo se uzima u obzir u izračunavanju ukupnog prihoda iz provjerljivih izvora.

U odjeljku APD o prihodima širi je problem što izvjestan broj anketiranih odbija da odgovore ili za čitav ovaj odjeljak ili o tipu ili iznosu konkretnih izvora prihoda. 240 od 18.183 anketiranih odbilo je da odgovori da li primaju platu od lokalnog poslodavca ili ne. Od 4.330

[3] Molimo pogledajte izvještaj «Budžetske novčane naknade za socijalnu zaštitu u Bosni i Hercegovini – šta radi, a šta ne (II) – Ciljanje budžetskih novčanih transfera – Teorija i dokazi u odabranim državama».

osoba koji su prijavili ovaj tip izvora prihoda, još 327 anketiranih nije navelo iznos ovog prihoda (oko 8 posto). Kad je riječ o platama koje primaju kao zaposleni kod stranih poslodavaca, 236 od 18.183 anketiranih odbilo je da odgovori da li primaju ovaj tip prihoda, iako je broj anketiranih koji su kasnije odbili da odgovore na ovo pitanje vrlo malen. Načelno, dio anketiranih koji ne popunjavaju odjeljak o prihodima je veći u Republici Srpskoj, dok su anketirani u Federaciji Bosne i Hercegovine skloniji da oklijevaju kod otkrivanja stvarnih iznosa. Štaviše, izbjegavanje odgovora na ova pitanja je posebno vjerovatnije u urbanim područjima RS, dok se u FBiH ne mogu lako identifikovati regionalne razlike. Sve u svemu, ova posmatranja ukazuju na potrebu da se pažljivo odvagne da li je, i u kojoj mjeri, poželjno uključiti prihode iz provjerljivih izvora.

Za potrebe ove analize, postoje u suštini dva načina kako se podaci o prihodima iz provjerljivih izvora mogu dodati na spisak faktora potencijalno povezanih sa potrošnjom domaćinstava u modelu indirektnog imovinskog cenzusa: prvo, vještačka varijabla bi pokazala da li bar jedan član domaćinstva prijavljuje platu kao zaposleni kod lokalnog ili stranog poslodavca. Drugo, neprekidna varijabla bi ukazala na iznos ukupnog prihoda domaćinstva od plata zaposlenih kod domaćih ili stranih poslodavaca i obuhvatila bi naknade za topli obrok i prijevoz, ako se isplaćuju povrh plate. Ova varijabla se dalje prilagođava za veličinu domaćinstva po skali OECD 1 i transformiše u svoj logaritam da se izbjegnu pristrasne procjene uzrokovane asimetričnošću distribucije ove varijable.

Indirektni imovinski cenzus nakon filtera

Razmatrali smo efekte primjene filtera povrh procijenjenih formula indirektnog imovinskog cenzusa na efikasnost/učinkovitost ciljanja.

Odabrani filteri posjeduju karakteristike koje se načelno povezuju sa višim životnim standardom (tj. domaćinstvo koje posjeduje automobil ili koje je kupilo automobil u posljednjih 12 mjeseci, domaćinstvo koje posjeduje garažu, domaćinstvo koje posjeduje sekundarni stambeni objekat; domaćinstvo sa internet konekcijom; domaćinstvo koje posjeduje mobilni telefon). Ove karakteristike koriste se kao prvi eliminatorni kriterijum, ili filter, za utvrđivanje kvalifikovanosti domaćinstva. Na primjer, osoba koja je član domaćinstva koje posjeduje automobil ne bi došla u obzir za dodjelu socijalne pomoći, pa će se prema tome model indirektnog imovinskog cenzusa primjenjivati samo na ljude bez automobila.

Dodali smo filtere najefikasnijim modelima indirektnog imovinskog cenzusa u FBiH i RS i procijenili njihove rezultate za obim programa od 10%, 15% i 20%. Poredili smo efekat dodavanja specifičnih filtera na učinak u osnovnom scenariju (indirektni imovinski cenzus bez filtera), uzimajući u obzir ne samo promjenu kod greške uključenja i isključenja, već i promjenu obima programa.

Razmatranje ovog hibridnog modela omogućava nam da procijenimo da li primjena različitih filtera može unaprijediti efikasnost/učinkovitost ciljanja najboljih modela indirektnog imovinskog cenzusa, bilo u pogledu smanjenja greške uključenja kao i uopšte poboljšanja orijentacije na siromašne u distribuciji.

Izdaci za komunalije

Ispitivali smo efikasnost jednog mehanizma ciljanja koji je zasnovan na izdacima za komunalije, konkretno na izdacima za električnu energiju i vodovod/kanalizaciju. Prva analiza izdataka za komunalije pokazuje da oko 27% stanovništva FBiH i 43% stanovništva RS ne

prijavljuje nikakve izdatke za vodovod ili kanalizaciju. Sljedstveno tome, izdaci za vodovod i kanalizaciju ne omogućavaju dovoljno razlikovanje između siromašnijih i imućnijih domaćinstava. Nasuprot tome, bukvalno svako domaćinstvo je povezano na električnu mrežu i plaća električnu energiju. Izdaci za električnu energiju su pozitivno povezani sa ukupnom potrošnjom (v. grafikon A 1 u dodatku). Stoga bi izdaci za električnu energiju mogli biti adekvatan zamjenski indikator blagostanja domaćinstva. Stoga vrijedi ispitati efikasnost modela ciljanja koji se zasnivaju na izdacima za električnu energiju.

Pošto je anketa APD izvedena tokom perioda od dvanaest mjeseci, izdaci za električnu energiju koje su prijavljivala razna domaćinstva odgovaraju različitim mjesecima (grafikon A 2 u dodatku prikazuje sezonske varijacije u izdacima za električnu energiju). Prijavljeni izdaci se stoga ne mogu porediti, ako nisu desezonirani. Za desezoniranje izdataka za električnu energiju primjenjujemo tehniku kojom se procjenjuju prosječni mjesečni izdaci za električnu energiju u 2011. godini za svako domaćinstvo na osnovi izdataka za električnu energiju prijavljenih u anketi.

Ovaj metod koji smo koristili za desezoniranje ima više koraka. Prvo, primjenjujemo regresiju običnom metodom najmanjih kvadrata da procijenimo efekat različitih mjeseci na izdatke za električnu energiju. Regresijska jednačina može se pisati ovako:

$$\ln(C_{ih}) = \alpha_{im} D_{im} + \beta x' + \varepsilon_{ih},$$

pri čemu je $\ln(C_{ih})$ prirodni logaritam prijavljenih izdataka domaćinstva za električnu energiju, α_{im} je procijenjeni efekat mjeseca m na izdatke za električnu energiju, D_{im} je binarna varijabla čija vrijednost je 1 ako je dati izdatak prijavljen u mjesecu m, a 0 ako je izdatak prijavljen u bilo kom drugom mjesecu, β je vektor koeficijenata, x' je vektor opisnih varijabli za dato domaćinstvo, a ε_{ih} je stohastički član. Prirodni logaritam izdataka za električnu energiju koristi se pošto je distribucija veoma asimetrična udesno, što može dovesti do pristrasnih procjena. Ponderi za uzorkovanje na individualnom nivou primjenjuju se da se dati uzorak učini reprezentativnim za cijelu populaciju.

Drugo, koristimo procijenjene mjesečne efekte α_{im} i stvarni prijavljeni iznos C_{ih} (za mjesec h) za izračunavanje procjene izdataka domaćinstva za električnu energiju za cijelu godinu ($\hat{Y}$). Primjenjujemo ovu jednačinu:

$$\hat{Y} = e^{\ln(C_{ih}) - \alpha_{ih} D_{ih}} \sum_{m=1}^{12} e^{\alpha_{im} D_{im}}$$

Treće, da bismo dobili prosječan mjesečni izdatak za 2011. godinu, jednostavno dijelimo procijenjeni godišnji izdatak sa 12:

$$C_{im} = \frac{\hat{Y}}{12}$$

Pošto smo izračunali procjenu prosječnih mjesečnih izdataka za električnu energiju, simuliramo efikasnost/učinkovitost ciljanja dva mehanizma. Kod prvog, 10, 15 i 20% najsiromašnijih pojedinaca identifikuju se na osnovi procijenjenih mjesečnih izdataka za električnu energiju po osobi. Kod drugog, isto se postiže na osnovi procijenjenih mjesečnih izdataka po osobi i za električnu energiju i za vodovod/kanalizaciju.

2.4 Prezentacija i tumačenje rezultata

Efikasnost svih mehanizama ciljanja ocjenjuje se na osnovi obuhvata I distribucije korisnika koje dati mehanizam identifikuje kao kvalifikovane za neki socijalni transfer. U tu svrhu,

cjelokupna populacija se rangira po svom blagostanju i grupiše u pet kvantila po potrošnji, u rasponu od najsiromašnijih do najbogatijih 20 procenata populacije. Ove kvantile potrošnje zasnivaju se mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije transfera budžetskih naknada za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%.

Pod *obuhvatom* korisnika misli se na onaj dio svake kvantile koji se kvalifikuje za transfer i on se izračunava dijeljenjem broja domaćinstava koja žive u domaćinstvu gdje se bar jedan član kvalifikovao za transfer sa ukupnim brojem osoba u toj kvantili. *Distribucija* korisnika izračunava se dijeljenjem broja pojedinaca u datoj kvantili koji žive u domaćinstvu sa najmanje jednim korisnikom sa ukupnim brojem pojedinaca koji žive u korisničkim domaćinstvima. Uzimamo da je stopa tačnosti ciljanja 100%, a to znači da prezentirane stope obuhvata i distribucije predstavljaju idealan slučaj savršene implementacije mehanizma ciljanja. Napominjemo da ovo ne važi za model gdje se postojeći prihodovni test kombinuje sa dodatnim filterskim varijablama. U ovom drugom slučaju, simulacija se zasniva na sadašnjoj efikasnosti/učinkovitosti ciljanja, pri čemu se uzimaju u obzir postojeće greške u implementaciji.

Izračunavanje *greške isključenja* i *greške uključenja* zasniva se na pretpostavci da najsiromašnijih 20% populacije treba da dobiva neku naknadu. Kad razmatra analiza siromaštva u BiH, razne predstavljene procjene dosljedno se kreću oko ovog praga.[4] Sljedstveno tome, greška isključenja izračunava se tako što se od 100% oduzme stopa obuhvata korisnika u najsiromašnijoj kvantili, a greška uključenja jednaka je 100% minus udio korisnika koji pripadaju najsiromašnijoj kvantili.

	Ciljna grupa (Najsiromašnijih 20%)	Ne-ciljna grupa (Nesiromašnih 80%)
Pojedinac prima transfer	Uspjeh	Greška uključenja
Pojedinac ne prima transfer	Greška isključenja	Uspjeh

Pošto su obuhvat i distribucija korisnika osjetljivi na veličinu programa, na kraju prezentiram ove indikatore za programe različitih veličina. Na primjer, kako se dati program povećava, smanjuje se greška isključenja, a greška uključenja obično se povećava. Ako je bilo primjenljivo, simulirali smo programe koji su obuhvatili najsiromašnijih 10, 15 ili 20% stanovništva.

2.5 Referentna vrijednost

Referentna vrijednost za ocjenu novih mehanizama ciljanja je efikasnost/učinkovitost ciljanja postojećih budžetskih naknada u pogledu obuhvata i distribucije korisnika i distribucije

[4] Molimo da pogledate izvještaj «Siromaštvo u BiH 2011 – Trendovi, postignuća i indikatori preciznosti ciljanja budžetskih transfera za socijalnu zaštitu u BiH u 2011. godini».

naknada. U budžetske naknade spadaju naknade za civilno stanovništvo i naknade za veterane koje su navedene samo radi poređenja. Budžetske naknade za civilno stanovništvo dalje se dijele na slijedeće kategorije:[5]

- civilne žrtve rata;
- naknade za osobe s invaliditetom koje nisu povezane s ratom – invalidnine;
- porodični i dodatak za dječju zaštitu;
- socijalna pomoć u krajnjoj nuždi.

Tabele 1 do 6 prikazuju obuhvat i distribuciju korisnika, kao i distribuciju naknada za FBiH i RS

[5] Molimo pogledajte prvi dio izvještaja «Budžetske novčane naknade za socijalnu zaštitu u Bosni i Hercegovini – Šta funkcioniše, a šta ne» koji sadrži pregled i analizu važeće legislative o budžetskim novčanim naknadama u Federaciji Bosne i Hercegovine (FBiH) i Republici Srpskoj (RS).

Tabela 1. Obuhvat naknada za budžetske novčane naknade, FBiH, 2011**.**

	I	II	III	IV	V	Ukupno
Budžetski novčani transferi (B6-B23, B26-B29)	22,3	19,1	14,4	10,6	9,1	15,1
Boračko invalidske naknade (B6-B10)	9,2	10,0	9,0	6,2	4,4	7,8
Naknade za civilno stanovništvo (B11-B23, B26-B29)	13,9	11,0	6,7	5,6	4,9	8,4
Civilne žrtve rata (B11-B17)*	0,9	1,6	0,8	0,7	1,1	1,0
Neratne naknade za osobe s invaliditetom – invalidnina (B18-B19)	3,7	3,1	2,5	1,6	1,2	2,4
Porodični i dječji dodatak (B21-B23)	6,4	6,2	2,8	3,8	2,3	4,3
Socijalna pomoć u krajnjoj nuždi (B26-B29)	3,5	1,3	1,0	0,3	0,6	1,4

Napomena: Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije datog transfera, uzimajući da je granična sklonost povećanju potrošnje 33 procenata. Primijenjeni su individualni ponderi. *Nije značajno na nivou od 10%. *Izvor:* Vlastiti proračuni zasnovani na APD 2011.

Tabela 2. Distribucija korisnika budžetskih novčanih naknada u FBiH, u %, 2011.

	I	II	III	IV	V	Ukupno
Budžetski novčani transferi (B6-B23, B26-B29)	29,5	25,4	19,0	14,1	12,0	100,0
Boračko invalidske naknade (B6-B10)	23,7	25,8	23,2	16,0	11,4	100,0
Naknade za civilno stanovništvo (B11-B23, B26-B29)	33,2	26,1	15,9	13,2	11,6	100,0
Civilne žrtve rata (B11-B17)*	18,4	31,5	15,5	13,1	21,6	100,0
Neratne naknade za osobe s invaliditetom – invalidnina (B18-B19)	30,3	25,3	20,5	13,6	10,3	100,0
Porodični i dječji dodatak (B21-B23)	29,8	29,1	12,9	17,5	10,7	100,0
Socijalna pomoć u krajnjoj nuždi (B26-B29)	52,1	18,8	15,4	4,2	9,5	100,0

Napomena: Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije datog transfera, uzimajući da je granična sklonost povećanju potrošnje 33 procenata. Primijenjeni su individualni ponderi. *Nije značajno na nivou od 10%. *Izvor:* Vlastiti proračuni zasnovani na APD 2011.

Tabela 3. Distribucija budžetskih novčanih naknada u FBiH, u %, 2011.

	I	II	III	IV	V	Ukupno
Budžetski novčani transferi (B6-B23, B26-B29)	21,3	22,6	20,1	17,1	19,0	100,0
Boračko invalidske naknade (B6-B10)	19,1	22,0	21,8	20,7	16,4	100,0
Naknade za civilno stanovništvo (B11-B23, B26-B29)	24,5	23,5	16,3	13,6	22,2	100,0
Civilne žrtve rata (B11-B17)	13,3	25,8	17,1	10,0	33,9	100,0
Neratne naknade za osobe s invaliditetom – invalidnina (B18-B19)	22,3	25,9	21,5	17,2	13,1	100,0
Porodični i dječji dodatak (B21-B23)	21,5	24,6	8,1	20,8	25,1	100,0
Socijalna pomoć u krajnjoj nuždi (B26-B29)	41,2	15,8	11,2	5,9	26,0	100,0

Napomena: Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije datog transfera, uzimajući da je granična sklonost povećanju potrošnje 33 procenata. Primijenjeni su individualni ponderi. *Izvor:* Vlastiti proračuni zasnovani na APD 2011.

Tabela 4. Obuhvat naknada za budžetske novčane naknade, RS, u%, 2011.

	I	II	III	IV	V	Ukupno
Budžetski novčani transferi (B6-B23, B26-B29)	31,6	25,8	19,9	18,1	16,4	22,4
Boračko invalidske naknade (B6-B10)*	15,5	13,4	14,2	11,6	11,5	13,2
Naknade za civilno stanovništvo (B11-B23, B26-B29)	20,5	15,6	8,0	7,0	6,4	11,5
Civilne žrtve rata (B11-B17)	1,0	2,4	0,9	0,9	0,1	1,1
Neratne naknade za osobe s invaliditetom – invalidnina (B18-B19)*	1,3	1,4	1,6	2,1	0,5	1,4
Porodični i dječji dodatak (B21-B23)	15,8	10,5	5,1	4,2	5,8	8,3
Socijalna pomoć u krajnjoj nuždi (B26-B29)	4,0	1,7	0,9	0,4	0,0	1,4

Napomena: Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije datog transfera, uzimajući da je granična sklonost povećanju potrošnje 33 procenata. Primijenjeni su individualni ponderi. *Nije značajno na nivou od 10%. *Izvor:* Vlastiti proračuni zasnovani na APD 2011.

Tabela 5. Distribucija korisnika budžetskih novčanih naknada u RS, u %, 2011.

	I	II	III	IV	V	Ukupno
Budžetski novčani transferi (B6-B23, B26-B29)	28.3	23.0	17.8	16.2	14.7	100.0
Boračko invalidske naknade (B6-B10)*	23.5	20.2	21.5	17.5	17.3	100.0
Naknade za civilno stanovništvo (B11-B23, B26-B29)	35.7	27.1	13.9	12.2	11.1	100.0
Civilne žrtve rata (B11-B17)	19.1	44.1	17.6	16.4	2.8	100.0
Neratne naknade za osobe s invaliditetom – invalidnina (B18-B19)*	19.2	20.3	22.9	30.7	6.9	100.0
Porodični i dječji dodatak (B21-B23)	38.4	25.2	12.3	10.1	14.0	100.0
Socijalna pomoć u krajnjoj nuždi (B26-B29)	56.4	24.8	12.5	6.3	0.0	100.0

Napomena: Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije datog transfera, uzimajući da je granična sklonost povećanju potrošnje 33 procenata. Primijenjeni su individualni ponderi. *Nije značajno na nivou od 10%. *Izvor:* Vlastiti proračuni zasnovani na APD 2011.

Tabela 6. Distribucija budžetskih novčanih naknada u RS, u %, 2011.

	I	II	III	IV	V	Ukupno
Budžetski novčani transferi (B6-B23, B26-B29)	28.5	21.4	18.3	15.7	16.1	100.0
Boračko invalidske naknade (B6-B10)	21.5	20.4	18.9	17.6	21.6	100.0
Naknade za civilno stanovništvo (B11-B23, B26-B29)	39.4	27.7	14.6	12.2	6.2	100.0
Civilne žrtve rata (B11-B17)	28.5	42.5	10.4	14.3	4.3	100.0
Neratne naknade za osobe s invaliditetom – invalidnina (B18-B19)	13.3	13.1	39.8	31.3	2.6	100.0
Porodični i dječji dodatak (B21-B23)	41.3	24.6	12.7	10.1	11.4	100.0
Socijalna pomoć u krajnjoj nuždi (B26-B29)	65.4	21.6	10.2	2.9	0.0	100.0

Napomena: Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije datog transfera, uzimajući da je granična sklonost povećanju potrošnje 33 procenata. Primijenjeni su individualni ponderi. *Izvor:* Vlastiti proračuni zasnovani na APD 2011.

3 Modeli indirektnog imovinskog cenzusa

3.1 Replikacija modela iz 2007. godine

Mehanizam indirektnog imovinskog cenzusa koji je razvijen 2009. godine na osnovu APD iz 2007. služi kao polazna vrijednost za ocjenu efikasnosti mehanizama ciljanja koji su predstavljeni u ovom izvještaju. Kao prvi korak, model se replicira sa podacima iz APD 2011. Pošto regionalno prilagođeni agregat potrošnje iz 2011. još nije dostupan, replikacija je ograničena na dva odvojena entitetska modela za Federaciju Bosne i Hercegovine i Republiku Srpsku, dok izvještaj za 2009. godinu takođe predstavlja modele za cijelu Bosnu i Hercegovinu, urbana/ruralna područja i najsiromašnijih 50 procenata populacije cijele zemlje.

Da bi se rezultati učinili usporedivim sa analizom koja je vršena 2009. godine, a istovremeno osigurala interna dosljednost sadašnje studije, radili smo na slijedeći način. Prvo, slijedili smo metodologiju iz 2009. što je tješnje moguće i procijenili smo indirektni imovinski cenzus s prirodnim logaritmom mjesečne potrošnje po osobi nakon transfera kao zavisnom varijablom. Ovaj indikator nivoa blagostanja kasnije se koristio i za izračunavanje obuhvata i distribucije korisnika. Ipak, mjera u kojoj su rezultati bili usporedivi bila je ograničena činjenicom da je izvještaj Svjetske banke iz 2009. godine prikazao samo rezultate modela indirektnog imovinskog cenzusa odvojeno za svaki entitet, dok su obuhvat i distribucija korisnika iz indirektnog imovinskog cenzusa iz 2007. godine dati jedino za BiH u cjelini. Drugo, procijenili smo model indirektnog imovinskog cenzusa za prirodni logaritam mjesečne potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transferisanja budžetskih naknada za civilno stanovništvo (uzimajući da je granična sklonost povećanju potrošnje jednaka 33%) kao zavisnu varijablu, pošto je ovo glavni indikator nivoa blagostanja korišten u ostatku izvještaja. Obuhvat i distribucija korisnika jednako su dati za kvantile ovog zadnjeg indikatora u skladu sa pristupom ovog izvještaja.

Prediktori koji su ušli u formulu za utvrđivanje izlaznih rezultata indirektnog imovinskog cenzusa odabrani su po modelu iz 2009. Kad je riječ o nezavisnoj varijabli iz modela indirektnog imovinskog cenzusa, važe slijedeća ograničenja: prvo, APD iz 2011. ne postavlja jasno pitanje da li dato domaćinstvo posjeduje kompjuter, već se pitanje odnosi i na štampače i kalkulatore. I mada smo u replikaciji ovo uključili kao nezavisnu varijablu, uzdržali smo se da koristimo ovo pitanje u kasnijim analizama, pošto nije dovoljno jasno. Drugo, pretpostavili smo da se “stan ima sanitarni priključak” odnosi na pitanje da li stan ima kanalizacioni sistem ili ne. Kad je riječ o izdacima za komunalije, odabrali smo da uključimo izdatke za slijedeće stavke, pri čemu se uvijek pozivamo na posljednji mjesec: električna energija, plin iz gradske mreže, centralno grijanje, vodovod i kanalizaciju, te odvoz smeća. Rezultati modela potrošnje navedeni su u tabeli A 1 u dodatku.

U Federaciji Bosne i Hercegovine, opisna moć modela potrošnje (s mjesečnom potrošnjom po osobi nakon transfera kao zavisnom varijablom) je neznatno manja nego 2007. (koeficijent determinacije iznosi 0,51 u poređenju sa 0,52 sa podacima iz APD 2007). Osim god indikatora “domaćinstvo posjeduje unutrašnji toalet i kupatilo”, svi ostali prediktori su značajni na nivou od 10%. Vrijedno je pažnje da je znak za “stan ima kanalizacioni sistem” je negativan i prema tome obrnut u odnosu na model iz 2007. godine, u kom “stan ima sanitarni priključak” ulazi u model s pozitivnim koeficijentom.

U Republici Srpskoj, koeficijent determinacije modela indirektnog imovinskog cenzusa (u kome je mjesečna potrošnja po osobi nakon transfera zavisna varijabla) iznosi 0,45, u poređenju sa 0,50 po podacima iz 2007. Niz prediktora nemaju značajnost na nivou od 10%

u replikaciji, uključujući tu broj djece mlađe od 14 godina i radni status nosioca domaćinstva, a neke karakteristike stambenog prostora (postojanje grejnih tijela, postojanje balkona, grijanje iz jednog izvora i posjedovanje hi-fi sistema). Načelno, ovo odražava dinamičnu evoluciju socijalnog statusa i ukazuje na potrebu da se formula indirektnog imovinskog cenzusa redovno ažurira.

Sve u svemu, modeli indirektnog imovinskog cenzusa sa mjesečnom potrošnjom po ekvivalentu odrasle osobe (skala OECD 1) prije transfera daju veoma slične rezultate i u FBiH i u RS, iako je opisna moć tih modela neznatno manja.

Procjene parametra običnih najmanjih kvadrata za model indirektnog imovinskog cenzusa predviđaju mjesečnu potrošnju domaćinstva po osobi nakon transfera/mjesečnu potrošnju po ekvivalentu odrasle osobe (skala OECD 1) prije transfera. Ova predviđanja koriste se da se utvrdi koji pojedinci su kvalifikovani za naknadu po tri različita praga (najsiromašnijih 10, 15 i 20%), kao i da se ocijeni efikasnost formule za određivanje rezultata. U tabelama 7 – 10 (str. 21 i 22) prikazani su simulirani obuhvat i distribucija korisnika za FBiH i RS. U skladu sa zavisnom varijablom, kvantile potrošnje zasnovane su ili na mjesečnoj potrošnji domaćinstva po članu nakon transfera, ili na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije transfera.

Iz poređenja ovih tabela nameću se tri zaključka. Prvo, obuhvat i distribucija korisnika indirektnog imovinskog cenzusa iz 2007. po podacima iz 2011. (vidi tabele 7 i 9) izgledaju uglavnom usporedive sa rezultatima postignutim sa podacima iz 2007, iako su ova poređenja uslovna pošto entitetske tabele nisu date u izvještaju Svjetske banke iz 2009. godine (v. Svjetska banka, 2009, str. 34). Slično tome, simulirana distribucija korisnika pokazuje da je greška uključenja manja u FBiH nego u RS. I na kraju, već smo vidjeli da su prediktori formule indirektnog imovinskog cenzusa iz 2007. godine neznatno prikladniji za predviđanje potrošnje po osobi nakon transfera nego po ekvivalentu odrasle osobe (skala OECD 1) prije transfera. Posljedica je da ovi modeli takođe daju neznatno slabije rezultate pri identifikaciji korisnika.

Tabela 7. Obuhvat i distribucija korisnika po modelu indirektnog imovinskog cenzusa iz 2007 (po podacima iz 2011.), za različit obim programa, po kvantilama potrošnje po osobi nakon transfera, FBiH

	I	II	III	IV	V	Ukupno	
Obuhvat (u %)							*Greška isključenja*
Obim programa: 10%	36.0	8.9	4.1	0.5	0.7	10.0	64.0
Obim programa: 15%	47.4	16.5	7.7	2.2	1.3	15.0	52.6
Obim programa; 20%	58.6	22.7	12.7	4.5	1.8	20.0	41.5
Distribucija (u %)							*Greška uključenja*
Obim programa: 10%	71.6	17.8	8.2	1.0	1.5	100.0	28.4
Obim programa: 15%	63.0	22.0	10.3	3.0	1.7	100.0	37.0
Obim programa: 20%	58.4	22.7	12.7	4.5	1.8	100.0	41.6

Napomena: Zavisna varijabla modela indirektnog imovinskog cenzusa je logaritam mjesečne potrošnje po osobi nakon transfera. Korišteni su isti prediktori kao i u dokumentu Svjetske banke (2009, str. 71-72). Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po osobi nakon transfera (pristup iz dokumenta Svjetske banke (2009)). Primijenjeni su ponderi za uzorkovanje na individualnom nivou.

Tabela 8. Obuhvat i distribucija korisnika modela indirektnog imovinskog cenzusa iz 2007. godine (sa podacima za 2011.), različiti obimi programa, po kvantilama za potrošnju po ekvivalentu odrasle osobe (skala OECD 1), prije transfera, za FBiH

	I	II	III	IV	V	Ukupno	
Obuhvat (u %)							*Greška isključenja*
Obim programa: 10%	33.3	9.7	3.6	2.1	1.3	10.0	66.7
Obim programa: 15%	46.4	16.7	6.8	3.7	1.6	15.0	53.6
Obim programa; 20%	56.9	25.1	10.1	5.7	2.3	20.0	43.1
Distribucija (u %)							*Greška uključenja*
Obim programa: 10%	66.5	19.5	7.1	4.2	2.6	100.0	33.5
Obim programa: 15%	61.6	22.3	9.0	4.9	2.2	100.0	38.4
Obim programa: 20%	56.7	25.2	10.1	5.7	2.3	100.0	43.3

Napomena: Zavisna varijabla modela indirektnog imovinskog cenzusa je logaritam mjesečne potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera budžetskih naknada za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Korišteni su isti prediktori kao i u dokumentu Svjetske banke (2009, str. 71-72). Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou.

Tabela 9. Obuhvat i distribucija korisnika modela indirektnog imovinskog cenzusa iz 2007 (sa podacima za 2011.), različiti obimi programa, po kvantilama potrošnje po stanovniku nakon transfera, u RS.

	I	II	III	IV	V	Ukupno	
Obuhvat (u %)							*Greška isključenja*
Obim programa: 10%	33.2	11.0	3.8	2.2	0.0	10.0	66.8
Obim programa: 15%	43.8	20.5	7.2	3.9	0.0	15.0	56.2
Obim programa; 20%	54.8	28.1	11.0	5.4	0.9	20.0	45.2
Distribucija (u %)							*Greška uključenja*
Obim programa: 10%	65.8	22.0	7.7	4.5	0.0	100.0	34.2
Obim programa: 15%	57.8	27.3	9.7	5.2	0.0	100.0	42.2
Obim programa: 20%	54.5	28.2	11.0	5.4	0.9	100.0	45.6

Napomena: Zavisna varijabla modela indirektnog imovinskog cenzusa je logaritam mjesečne potrošnje po osobi nakon transfera. Korišteni su isti prediktori kao i u dokumentu Svjetske banke (2009, str. 71-72). Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po osobi nakon transfera (pristup iz dokumenta Svjetske banke (2009)). Primijenjeni su ponderi za uzorkovanje na individualnom nivou.

Tabela 10. Obuhvat i distribucija korisnika modela indirektnog imovinskog cenzusa iz 2007. godine (sa podacima za 2011. godinu, različiti obimi programa, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS

	I	II	III	IV	V	Ukupno	
Obuhvat (u %)							*Greška isključenja*
Obim programa: 10%	31.2	12.1	5.2	1.9	1.0	10.2	68.8
Obim programa: 15%	41.9	19.3	9.1	4.3	1.9	15.2	58.1
Obim programa; 20%	51.3	27.2	13.0	7.2	3.0	20.3	48.8
Distribucija (u %)							*Greška uključenja*
Obim programa: 10%	60.4	23.8	10.2	3.7	1.9	100.0	39.6
Obim programa: 15%	54.5	25.4	12.0	5.6	2.5	100.0	45.5
Obim programa: 20%	50.1	26.9	12.9	7.1	3.0	100.0	49.9

Napomena: Zavisna varijabla modela indirektnog imovinskog cenzusa je logaritam mjesečne potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera budžetskih naknada za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Korišteni su isti prediktori kao i u dokumentu Svjetske banke (2009, str. 71-72). Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou.

3.2 Novi modeli indirektnog imovinskog cenzusa

Novi modeli potrošnje procjenjuju se odvojeno za Federaciju Bosne i Hercegovine i Republiku Srpsku. Pored modela zasnovanih na kompletnom stanovništvu datog entiteta, razradili smo odvojene modele i za urbane i ruralne regione da bismo odrazili i kvalitetnije obuhvatili razlike u uslovima života.[6]

Rezultati modela potrošnje ukazuju da su zaposlenost ili srednje ili više obrazovanje nosioca domaćinstva u snažnoj i pozitivnoj korelaciji sa nivoom blagostanja domaćinstva. Među ostale karakteristike koje su obično u pozitivnoj vezi sa višim nivoom potrošnje spadaju posjedovanje sekundarnog stana; kupovina novog ili polovnog automobila u posljednjih dvanaest mjeseci; posjedovanje mašine za pranje posuđa; posjedovanje mobilnog telefona; i korištenje neke vrste komunikacionog paketa. Veličina domaćinstva i broj članova po jednoj sobi su u snažnoj negativnoj korelaciji sa nivoom blagostanja domaćinstva. Iako se ovi posebni modeli razlikuju u pogledu nekih obuhvaćenih karakteristika, ove varijable su statistički značajne u svim procijenjenim modelima indirektnog imovinskog cenzusa, kako za FBiH i RS, tako i za ruralne i urbane regije unutar dva entiteta.

Pa ipak, ima slučajeva u kojima koeficijenti karakteristika stana ulaze u modele potrošnje sa predznakom suprotnim od očekivanog. Najznačajnije je da su povezanost stana sa sistemom kanalizacije ili dovodom pitke vode negativno povezani s potrošnjom. I mada nam je bilo jasno da se ovi koeficijenti ne mogu tumačiti u uzročnom smislu, odlučili smo da ove varijable isključimo iz inicijalnog skupa karakteristika zbog mogućih problema sa prihvatanjem formule u javnosti. Povrh toga, može se primijetiti da je broj djece u domaćinstvu u pozitivnoj vezi sa nivoom blagostanja domaćinstva. U ovom slučaju, treba imati na umu da modeli uključuju korekcije za veličinu domaćinstva, kao i da je ukupni broj članova domaćinstva u negativnoj korelaciji s nivoom potrošnje.

Iz procijenjenih modela indirektnog imovinskog cenzusa vidljivo je da je opisna moć regresija veća za FBiH, tj. da su obuhvaćene varijable u neznatno boljem položaju da posluže kao zamjenska varijabla za potrošnju u tom entitetu. Odatle su greške uključenja i isključenja manje kad se formule za ciljanje korisnika primjenjuju u FBiH. Za oba entiteta, koeficijent determinacije modela za ruralna područja manji je nego koeficijent determinacije modela za ukupnu populaciju. Međutim, kad je riječ o RS, opisna moć urbanog modela (R^2 = 0,51) je mnogo viša nego opisna moć modela zasnovanog na cjelokupnoj populaciji (R^2 = 0,48), što doprinosi znatno većoj preciznosti kombinovane ruralno/urbane formule u RS.

Tabele 11-14 (str. 25-26) prikazuju simulirani obuhvat i distribuciju korisnika kako bi ih identifikovali novi modeli indirektnog imovinskog cenzusa, bilo da su zasnovani na jednoj formuli za čitav entitet ili da uzimaju u obzir razlike između urbanih i ruralnih područja.

Nezavisno od toga da li su simulacije za FBiH zasnovane na modelu za cjelokupnu populaciju ili za odvojene urbanu i ruralnu populaciju, predviđeni obuhvat najsiromašnije kvantile za program koji cilja najsiromašnijih 10% stanovništva iznosi oko 37%. U jednom takvom programu očekuje se da oko 75% svih korisnika pripadaju najsiromašnijoj petini stanovništva. Kako se povećava obim simuliranog programa, postaje vidljivo da model koji uzima u obzir razlike između urbane i ruralne populacije daje preciznije rezultate. Za obim programa koji cilja najsiromašnijih 15% stanovništva, greške uključenja i isključenja su 50%, odnosno 33% za ukupni model, ali se neznatno smanjuju na 49%, odnosno 32% kod modela koji pravi razliku između urbanih i ruralnih područja.

[6] Svi modeli se mogu naći u dodatku.

Za Republiku Srpsku, dosljedno je slučaj da urbani/ruralni model daje bolje rezultate nego model zasnovan na cjelokupnoj populaciji. Na primjer, za program koji je namijenjen da obuhvati najsiromašnijih 10% stanovništva, uzimanje u obzir razlika između urbanih i ruralnih područja smanjuje grešku isključenja sa 67% na 62%, a grešku uključenja sa 35% na 25% (v. tabele 13 i 14).

Zaključci koji slijede proizišli su iz pregleda ovih rezultata. Prvo, efikasnost/učinkovitost ciljanja se poboljšava zasnivanjem identifikacije korisnika na odvojenim formulama indirektnog imovinskog cenzusa za urbana i ruralna područja. Ovo se veže sa činjenicom da dva odvojena modela potrošnje za urbana i ruralna područja bolje obuhvataju raznovrsne uslove života u urbanim i ruralnim dijelovima entiteta. Posebno u RS, urbana/ruralna formula je preciznije identifikovala korisnike.

Drugo, efikasnost/učinkovitost ciljanja je bolja u FBiH nego u RS kada su modeli zasnovani na ukupnoj populaciji (vidjeti tabele 11 i 13). Ovaj zaključak je u skladu sa nalazom da je koeficijent determinacije modela potrošnje viši u FBiH nego u RS. Ipak, poređenje tabela 12 i 14 pokazuje da je postignuta efikasnost/učinkovitost ciljanja sličnija u FBiH i RS čim se urbana i ruralna područja tretiraju zasebno. Sljedstveno tome, ovo je dodatni razlog da formule indirektnog imovinskog cenzusa za urbana i ruralna domaćinstva budu različite.

Kako je gore opisano, usporedivost ovih modela sa modelom predloženim 2007. godine je ograničena. Međutim, iz replikacije modela iz 2007. godine možemo vidjeti da je efikasnost/učinkovitost ciljanja novokalibriranih modela veća; to je rezultat koji je očito zasnovan na činjenici da se socijalna zaštita razvija i da se evoluirajući obrasci blagostanja domaćinstava bolje prepoznaju kroz nove modele.

Tabela 11. Obuhvat i distribucija korisnika novokalibriranog modela indirektnog imovinskog cenzusa zasnovanog na cjelokupnoj populaciji (sa podacima iz 2011.), različitim obimom programa, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za FBiH

	I	II	III	IV	V	Ukupno	
Obuhvat (u %)							*Greška isključenja*
Obim programa: 10%	37.6	8.8	2.3	1.0	0.3	10.0	62.4
Obim programa: 15%	50.0	16.4	4.9	3.0	0.7	15.0	50.0
Obim programa; 20%	59.7	25.5	9.0	4.3	1.6	20.0	40.3
Distribucija (u %)							*Greška uključenja*
Obim programa: 10%	75.3	17.5	4.5	2.0	0.7	100.0	24.7
Obim programa: 15%	66.7	21.9	6.5	4.0	0.9	100.0	33.3
Obim programa: 20%	59.7	25.5	9.0	4.3	1.6	100.0	40.3

Napomena: Zavisna varijabla modela indirektnog imovinskog cenzusa je logaritam mjesečne potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera budžetskih naknada za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou.

Tabela 12. Obuhvat i distribucija korisnika novokalibriranog modela indirektnog imovinskog cenzusa zasnovanog na odvojenim ruralnim/urbanim područjima (s podacima za 2011.), različitim obimom programa, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1), prije transfera, za FBiH

	I	II	III	IV	V	Ukupno	
Obuhvat (u %)							*Greška isključenja*
Obim programa: 10%	37.9	8.7	2.7	0.7	0.3	10.0	62.1
Obim programa: 15%	51.4	15.4	4.9	2.9	0.9	15.0	48.7
Obim programa; 20%	61.6	24.1	8.6	4.4	1.5	20.0	38.4
Distribucija (u %)							*Greška uključenja*
Obim programa: 10%	75.2	17.3	5.5	1.4	0.7	100.0	24.8
Obim programa: 15%	68.0	20.6	6.5	3.8	1.1	100.0	32.0
Obim programa: 20%	61.3	24.2	8.6	4.4	1.5	100.0	38.7

Napomena: Zavisna varijabla modela indirektnog imovinskog cenzusa je logaritam mjesečne potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera budžetskih naknada za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou.

Tabela 13. Obuhvat i distribucija korisnika novokalibriranog modela indirektnog imovinskog cenzusa zasnovanog na cjelokupnoj populaciji (sa podacima iz 2011.), različitim obimom programa, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS

	I	II	III	IV	V	Ukupno	
Obuhvat (u %)							*Greška isključenja*
Obim programa: 10%	33.4	12.7	3.9	0.4	0.5	10.2	66.7
Obim programa: 15%	45.7	19.8	7.2	2.2	1.5	15.3	54.3
Obim programa; 20%	55.2	28.3	12.1	4.4	2.0	20.3	44.8
Distribucija (u %)							*Greška uključenja*
Obim programa: 10%	65.4	25.2	7.7	0.7	1.0	100.0	34.6
Obim programa: 15%	59.6	26.0	9.5	2.9	2.0	100.0	40.4
Obim programa: 20%	54.0	27.9	11.9	4.3	1.9	100.0	46.0

Napomena: Zavisna varijabla modela indirektnog imovinskog cenzusa je logaritam mjesečne potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera budžetskih naknada za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou.

Tabela 14. Obuhvat i distribucija korisnika novokalibriranog modela indirektnog imovinskog cenzusa zasnovanog na odvojenim ruralnim/urbanim područjima (s podacima za 2011.), različitim obimom programa, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1), prije transfera, za RS

	I	II	III	IV	V	Ukupno	
Obuhvat (u %)							*Greška isključenja*
Obim programa: 10%	38.1	7.0	3.7	1.6	0.5	10.1	61.9
Obim programa: 15%	47.8	18.0	7.3	2.6	0.9	15.3	52.2
Obim programa; 20%	56.5	27.3	11.5	5.4	1.5	20.4	43.5
Distribucija (u %)							*Greška uključenja*
Obim programa: 10%	74.8	13.7	7.3	3.2	1.0	100.0	25.2
Obim programa: 15%	62.3	23.6	9.6	3.4	1.2	100.0	37.7
Obim programa: 20%	55.1	26.8	11.3	5.3	1.5	100.0	44.9

Napomena: Zavisna varijabla modela indirektnog imovinskog cenzusa je logaritam mjesečne potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera budžetskih naknada za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou.

3.3 Postojeći prihodovni testovi s dodatnim filterima

Da se provjeri da li se efikasnost/učinkovitost ciljanja postojećih budžetskih naknada za civilno stanovništvo provjerenih prihodovnim cenzusom poboljšava ako se povrh sada primjenjivanog prihodovnog cenzusa primijene i dodatni filteri, simulirali smo efikasnost/učinkovitost ciljanja u slučaju kad se dato domaćinstvo kvalifikuje samo ako (1) trenutno prima neku budžetsku novčanu naknadu za civilno stanovništvo i (2) za nju ne važi određeno filtersko pitanje.

Odgovarajući filteri su se uglavnom birali na temelju nalaza iz modela indirektnog imovinskog cenzusa, koji ukazuju koje karakteristike stana ili trajnih potrošnih dobara su povezane sa višim nivoom blagostanja datog domaćinstva. Pojedinačno su razmatrani slijedeći filteri: da li domaćinstvo ima internet konekciju, mobilni telefon, sekundarni stan, garažu, automobil, automobil kupljen u posljednjih 12 mjeseci, ili novi ili polovni automobil kupljen u posljednjih 12 mjeseci. Kao i obično, simulacije su rađene odvojeno za FBiH i RS. Rezultati su sumirani u tabelama 15 i 16. U svakoj tabeli, prva linija ukazuje na efikasnost sadašnjih naknada za civilno stanovništvo provjerenih prihodovnim cenzusom i služi kao polazna vrijednost.

Sve u svemu, poređenje između obuhvata i distribucije korisnika prije i nakon primjene dodatnih filtera povrh sadašnjeg prihodovnog cenzusa ilustruje dobro poznat kompromis između greške uključenja i greške isključenja. U odnosu na polaznu vrijednost, primjenom dodatnih filtera logično se povećavaju greške isključenja, mada se doprinosi manjim greškama uključenja. Stoga je očito moguće znatno smanjiti greške uključenja, ali po cijenu isključenja znatnog dijela populacije koja je u stanju potrebe.

Na primjer, ako svi vlasnici mobilnih telefona u FBiH nisu *per se* diskvalifkovani za bilo koji budžetski novčani transfer za civilno stanovništvo koji se provjerava prihodovnim cenzusom, greška uključenja bi se smanjila sa 62% na 38%, a odlijevanje socijalnih naknada nekvalifikovanim domaćinstvima bi se takođe ograničilo. Međutim, u isto vrijeme greška isključenja se značajno povećava sa 91% na 99%. Nasuprot ovome, uzimanje u obzir da li domaćinstvo ima sekundarni stan ili je kupilo nov automobil u posljednjih dvanaest mjeseci ne povećava grešku isključenja, ali nije baš efikasno ni u smanjenju greške uključenja.

Simulacije su ponudile barem dvije opcije. Prvo, treba razmotriti isključivanje svih domaćinstava koja imaju internet konekciju. U FBiH, na primjer, ovo bi ukupni program smanjilo sa 5% na 3%, dok bi obuhvat najsiromašnije kvantile ostao oko 9% (vidjeti tabelu 15). U isto vrijeme, distribucija korisnika bila bi povoljnija, jer bi bili više koncentrisani u najnižoj kvantili. Isti efekat uočen je i u RS (vidjeti tabelu 16).

Druga opcija pojavljuje se u FBiH, gdje se posjedovanje automobila smatra dodatnim kriterijumom za prihodovni cenzus. I mada bi se obim programa znatno smanjio (sa 4,9% na 2,7%), obuhvat bi i dalje bio jednak 7,0%, u poređenju sa sadašnjih 9,0%. U isto vrijeme, distribucija korisnika bila bi više u korist siromašnih. Nasuprot ovome, u RS izgleda da ovo nije izvedivo, pošto bi obuhvat najsiromašnije kvantile naglo opao sa 18,6% na 10,5%.

Tabela 15. Obuhvat i distribucija korisnika, kao i distribucija naknada, uz primjenu dodatnih filtera povrh prihodovnog cenzusa koji se sada primjenjuje, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za FBiH

	I	II	III	IV	V	Ukupno	
Obuhvat korisnika (u %)							*Greška isključenja*
Polazna vrijednost	9,4	6,7	3,3	3,4	1,9	4,9	90,6
Domaćinstvo ima internet konekciju	8,6	3,8	2,0	2,0	0,8	3,4	91,4
Domaćinstvo ima mobilni telefon	1,4	0,4	0,1	0,3	0,1	0,5	98,6
Domaćinstvo ima sekundarni stan	9,1	6,6	3,3	3,4	1,4	4,8	90,9
Domaćinstvo ima garažu	7,0	3,9	2,6	2,0	0,9	3,3	93,0
Domaćinstvo ima automobil	7,0	2,9	1,1	1,7	0,5	2,7	93,1
Domaćinstvo je kupilo nov automobil u zadnjih 12 mjeseci	9,4	6,7	3,3	3,4	1,8	4,9	90,6
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	9,4	6,5	3,0	3,1	1,7	4,7	90,6
Distribucija korisnika (u %)							*Greška uključenja*
Polazna vrijednost	38,1	27,3	13,4	13,6	7,6	100,0	61,9
Domaćinstvo ima internet konekciju	50,1	21,9	11,8	11,5	4,7	100,0	49,9
Domaćinstvo ima mobilni telefon	61,8	15,5	2,3	14,7	5,7	100,0	38,2
Domaćinstvo ima sekundarni stan	38,3	27,8	13,9	14,2	5,8	100,0	61,7
Domaćinstvo ima garažu	42,9	23,7	16,1	12,1	5,2	100,0	57,1
Domaćinstvo ima automobil	52,6	22,2	8,5	12,9	3,9	100,0	47,5
Domaćinstvo je kupilo nov automobil u zadnjih 12 mjeseci	38,3	27,4	13,5	13,7	7,2	100,0	61,7
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	39,8	27,5	12,5	13,2	7,0	100,0	60,2
Distribucija naknada (u %)							*Odlijevanje*
Polazna vrijednost	35,4	23,0	11,6	10,7	19,3	100,0	64,6
Domaćinstvo ima internet konekciju	41,9	20,0	9,1	8,6	20,3	100,0	58,1
Domaćinstvo ima mobilni telefon	55,2	22,5	1,6	11,6	9,1	100,0	44,8
Domaćinstvo ima sekundarni stan	40,7	25,6	13,6	12,4	7,8	100,0	59,3
Domaćinstvo ima garažu	36,4	18,4	12,6	10,2	22,4	100,0	63,6
Domaćinstvo ima automobil	45,1	20,3	8,4	10,8	15,3	100,0	54,9
Domaćinstvo je kupilo nov automobil u zadnjih 12 mjeseci	35,4	23,0	11,6	10,7	19,3	100,0	64,6
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	36,7	23,0	10,8	10,4	19,1	100,0	63,3

Napomene: Domaćinstvo se kvalifikuje ako (1) trenutno prima budžetsku novčanu naknadu za civilno stanovništvo i (2) za nju ne važi dato filtersko pitanje, npr. da li posjeduje automobil. Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 19 prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje za 33%. Koriste se ponderi za uzorkovanje na individualnom nivou.

Tabela 16. Obuhvat i distribucija korisnika, kao i distribucija naknada, uz primjenu dodatnih filtera povrh prihodovnog cenzusa koji se sada primjenjuje, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS.

	I	II	III	IV	V	Ukupno	
Obuhvat korisnika (u %)							*Greška isključenja*
Polazna vrijednost	18,6	12,8	5,5	4,6	5,8	9,5	81,5
Domaćinstvo ima internet konekciju	15,2	10,4	2,7	3,0	3,2	6,9	84,8
Domaćinstvo ima mobilni telefon	1,7	0,9	0,2	0,2	0,0	0,6	98,3
Domaćinstvo ima sekundarni stan	18,6	12,8	5,5	3,6	5,2	9,1	81,5
Domaćinstvo ima garažu	12,7	5,5	3,7	2,0	2,7	5,3	87,3
Domaćinstvo ima automobil	10,5	4,6	1,8	1,3	1,1	3,9	89,6
Domaćinstvo je kupilo nov automobil u zadnjih 12 mjeseci	18,6	12,8	5,5	4,6	5,5	9,4	81,5
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	17,7	11,0	4,4	4,1	5,3	8,5	82,3
Distribucija korisnika (u %)							*Greška uključenja*
Polazna vrijednost	39,3	27,0	11,7	9,8	12,2	100,0	60,7
Domaćinstvo ima internet konekciju	44,1	30,0	7,8	8,8	9,3	100,0	55,9
Domaćinstvo ima mobilni telefon	56,7	28,8	7,2	7,3	0,0	100,0	43,3
Domaćinstvo ima sekundarni stan	40,7	28,0	12,1	7,9	11,3	100,0	59,3
Domaćinstvo ima garažu	47,6	20,8	13,9	7,6	10,1	100,0	52,4
Domaćinstvo ima automobil	54,4	23,9	9,5	6,8	5,5	100,0	45,6
Domaćinstvo je kupilo nov automobil u zadnjih 12 mjeseci	39,5	27,2	11,8	9,8	11,7	100,0	60,5
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	41,8	25,9	10,4	9,6	12,4	100,0	58,2
Distribucija naknada (u %)							*Odlijevanje*
Polazna vrijednost	47,4	24,4	12,2	8,0	7,9	100,0	52,6
Domaćinstvo ima internet konekciju	47,2	27,9	12,0	7,3	5,7	100,0	52,8
Domaćinstvo ima mobilni telefon	58,1	29,0	5,1	7,9	0,0	100,0	41,9
Domaćinstvo ima sekundarni stan	48,4	24,9	12,5	6,9	7,3	100,0	51,6
Domaćinstvo ima garažu	44,8	24,3	16,5	7,3	7,0	100,0	55,2
Domaćinstvo ima automobil	58,4	24,2	7,2	5,9	4,4	100,0	41,6
Domaćinstvo je kupilo nov automobil u zadnjih 12 mjeseci	47,5	24,5	12,3	8,0	7,7	100,0	52,5
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	49,7	24,5	9,4	8,4	8,1	100,0	50,3

Napomene: Domaćinstvo se kvalifikuje ako (1) trenutno prima budžetsku novčanu naknadu za civilno stanovništvo i (2) za nju ne važi dato filtersko pitanje, npr. da li posjeduje automobil. Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje za 33%. Koriste se ponderi za uzorkovanje na individualnom nivou.

4 Kategorijsko ciljanje

Karakteristike pojedinca ili domaćinstva koje su lako uočljive, teške za manipulaciju i koje su u korelaciji sa nižim nivoom blagostanja domaćinstva mogu poslužiti i kao mehanizmi ciljanja budžetskih naknada za civilno stanovništvo. Na primjer, domaćinstva sa mnogo (male) djece, nezaposleni članovi domaćinstva ili članovi domaćinstva sa invaliditetom obično imaju veću vjerovatnoću da će biti siromašni. Po kategorijskom ciljanju, domaćinstvo se automatski kvalifikuje za neke naknade čim za njega važi neka karakteristika.

Na osnovi nalaza iz profila siromaštva kao i modela indirektnog imovinskog cenzusa, slijedeće karakteristike domaćinstava odabrane su za simulaciju efikasnosti/učinkovitosti ciljanja kod kategorijskog ciljanja:

- bar jedno dijete mlađe od 18 godina;
- bar jedno dijete mlađe od 6 godina;
- dvoje ili više djece mlađih od 18 godina;
- dvoje ili više djece mlađih od 6 godina;
- troje ili više djece mlađih od 18 godina;
- domaćinstvo sa pet ili više članova;
- domaćinstvo sa šest ili više članova;
- nosilac domaćinstva je nesposobna za rad;
- nosilac domaćinstva ima rješenje o invaliditetu;
- bar jedan član domaćinstva ima rješenje o invaliditetu;
- omjer zavisnosti (broj članova domaćinstva podijeljen brojem zaposlenih) veći od 4.

Rezultati naših simulacija prikazani su u tabelama 17 i 18 (str. 31-32). Prvo pitanje za razmatranje je veličina identifikovanih grupa kao što se može vidjeti iz tabela o obuhvatu. Na primjer, pošto 57.0% stanovništva u FBiH i 49.0% stanovništva u RS živi u domaćinstvima sa djecom mlađom od 18 godina, veličina ove grupe je prevelika da bi je imalo smisla ciljati. Štaviše, prilikom tumačenja tabela važno je imati na umu da su greške isključenja i uključenja osjetljive na obim programa. Ako pretpostavimo da obim programa neće biti veći od 20% populacije, moguće je razmatrati slijedeće karakteristike domaćinstava: dvoje ili više djece mlađih od 6 godina; troje ili više djece mlađih od 18 godina; šest ili više članova domaćinstva; nosilac domaćinstva je nesposoban za rad; nosilac domaćinstva ima zvanično rješenje o invaliditetu; ili barem jedan član ima zvanično rješenje o invaliditetu, ili je indikator zavisnosti veći od 4.

Kad se dodatno uzmu u obzir obuhvat i distribucija korisnika, čini se da bi dvoje ili više djece mlađih od 6 godina ili troje ili više djece mlađih od 18 godina, šest ili više članova domaćinstva i nesposobnost za rad nosioca domaćinstva mogle biti korisne kategorije za ciljanje. U tim slučajevima, obuhvat najsiromašnije kvantile je veći nego među cjelokupnom populacijom, a distribucija korisnika bila bi koncentrisana u najnižoj kvantili.

Tabela 17. Obuhvat i distribucija korisnika primjenom kategorijskog ciljanja, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OEC 1) prije transfera, za FBiH

	I	II	III	IV	V	Ukupno	
Obuhvat (u %) Domaćinstvo ima…							*Greška isključenja*
…djecu mlađu od 18 godina	68.7	60.4	57.4	54.4	44.0	57.0	31.3
…djecu mlađu od 6 godina	28.2	23.6	21.0	20.4	15.7	21.8	71.9
…dvoje ili više djece mlađih od 18 godina	44.1	34.9	33.1	29.5	21.5	32.6	55.9
…dvoje ili više djece mlađih od 6 godina	9.4	6.1	4.8	4.2	3.6	5.6	90.6
…troje ili više djece mlađih od 18 godina	14.3	11.1	8.7	8.2	3.2	9.1	85.7
…pet ili više članova domaćinstva	42.3	36.0	30.4	25.6	13.8	29.6	57.7
…šest ili više članova domaćinstva	24.8	17.7	10.8	11.6	5.5	14.1	75.2
…nosioca koji je nesposoban za rad	4.6	1.8	2.0	1.1	0.8	2.1	95.4
…nosioca koji ima rješenje o invaliditetu	14.0	13.6	14.9	10.9	11.9	13.0	86.1
…bar jednog člana s rješenjem o invaliditetu	21.4	22.0	19.2	17.1	16.7	19.3	78.7
…indikator zavisnosti veći od 4	19.3	16.6	15.0	12.3	4.4	13.5	80.7
Distribucija korisnika (u %) Domaćinstvo ima…							*Greška uključenja*
…djecu mlađu od 18 godina	24.1	21.2	20.1	19.1	15.4	100.0	75.9
…djecu mlađu od 6 godina	25.9	21.7	19.3	18.8	14.4	100.0	74.2
…dvoje ili više djece mlađih od 18 godina	27.1	21.4	20.3	18.1	13.2	100.0	72.9
…dvoje ili više djece mlađih od 6 godina	33.5	21.7	17.1	15.0	12.7	100.0	66.5
…troje ili više djece mlađih od 18 godina	31.6	24.3	19.1	18.0	7.0	100.0	68.4
…pet ili više članova domaćinstva	28.6	24.3	20.5	17.3	9.3	100.0	71.4
…šest ili više članova domaćinstva	35.3	25.2	15.4	16.5	7.7	100.0	64.8
…nosioca koji je nesposoban za rad	44.7	17.4	19.1	10.8	8.0	100.0	55.3
…nosioca koji ima rješenje o invaliditetu	21.4	20.8	22.8	16.7	18.3	100.0	78.6
…bar jednog člana s rješenjem o invaliditetu	22.2	22.8	19.9	17.8	17.4	100.0	77.8
…indikator zavisnosti veći od 4	28.6	24.6	22.2	18.2	6.5	100.0	71.4

Napomene: Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih gotovinskih transfera za civilno stanovništvo, uzimajući da je granična sklonost ka povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou.

Tabela 18. Obuhvat i distribucija korisnika primjenom kategorijskog ciljanja, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS

	I	II	III	IV	V	Ukupno	
Obuhvat (u %) Domaćinstvo ima…							*Greška isključenja*
…djecu mlađu od 18 godina	60.0	50.7	48.0	47.6	38.6	49.0	40.1
…djecu mlađu od 6 godina	26.3	20.5	20.8	19.1	14.2	20.2	73.7
…dvoje ili više djece mlađih od 18 godina	41.9	31.9	30.2	30.8	21.3	31.2	58.1
…dvoje ili više djece mlađih od 6 godina	10.5	4.7	5.4	5.5	2.8	5.8	89.5
…troje ili više djece mlađih od 18 godina	18.5	11.1	7.6	6.5	4.3	9.6	81.5
…pet ili više članova domaćinstva	45.5	43.3	32.8	29.2	14.9	33.1	54.5
…šest ili više članova domaćinstva	27.9	20.4	17.1	13.5	8.3	17.5	72.1
…nosioca koji je nesposoban za rad	7.3	4.8	2.0	3.1	1.6	3.8	92.7
…nosioca koji ima rješenje o invaliditetu	9.0	9.0	12.0	10.7	7.0	9.5	91.1
…bar jednog člana s rješenjem o invaliditetu	13.9	12.9	17.2	17.9	10.1	14.4	86.2
…indikator zavisnosti veći od 4	17.9	18.0	14.5	6.9	4.4	12.3	82.1
Distribucija korisnika (u %) Domaćinstvo ima...							*Greška uključenja*
…djecu mlađu od 18 godina	24.5	20.7	19.6	19.4	15.8	100.0	75.5
…djecu mlađu od 6 godina	26.1	20.4	20.5	18.9	14.1	100.0	73.9
…dvoje ili više djece mlađih od 18 godina	26.9	20.5	19.3	19.7	13.6	100.0	73.1
…dvoje ili više djece mlađih od 6 godina	36.2	16.4	18.7	19.1	9.7	100.0	63.8
…troje ili više djece mlađih od 18 godina	38.6	23.1	15.9	13.6	8.9	100.0	61.4
…pet ili više članova domaćinstva	27.5	26.2	19.7	17.6	9.0	100.0	72.5
…šest ili više članova domaćinstva	32.0	23.4	19.6	15.5	9.5	100.0	68.0
…nosioca koji je nesposoban za rad	39.0	25.5	10.7	16.4	8.4	100.0	61.0
…nosioca koji ima rješenje o invaliditetu	18.7	19.0	25.3	22.4	14.7	100.0	81.4
…bar jednog člana s rješenjem o invaliditetu	19.2	17.9	23.9	25.0	14.0	100.0	80.8
…indikator zavisnosti veći od 4	29.0	29.3	23.5	11.1	7.1	100.0	71.0

Napomene: Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih gotovinskih transfera za civilno stanovništvo, uzimajući da je granična sklonost ka povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou.

5 Hibridne i druge metode ciljanja

5.1 Indirektni imovinski cenzus sa prihodima

Kao što je opisano u metodologiji (pogledajte odjeljak 2.3), odjeljak o prihodima u APD-u pati zbog relativno velike količine informacija koje nedostaju, posebno u pogledu stvarnih iznosa prihoda iz konkretnih izvora. Stoga je odlučeno da se prihodi iz provjerljivih izvora uključe kao binarna varijabla koja pokazuje da li bar jedan član domaćinstva prima platu od lokalnog ili stranog poslodavca. Ova zamjenska varijabla dodata je inicijalnom skupu varijabli za model indirektnog imovinskog cenzusa i analizirano je u kojoj mjeri ova dodatna varijabla povećava opisnu moć modela potrošnje, tj. u kojoj mjeri je povezana sa nivoom blagostanja domaćinstva. Ustanovljeno je da ova varijabla samo u jednom slučaju ulazi u konačni skup prediktora, naime u modelu indirektnog imovinskog cenzusa za ruralna područja u FBiH. U svim drugim modelima ova varijabla nije statistički značajna na nivou od 10% i stoga ne povećava opisnu moć tih modela. Za modele potrošnje za ruralna područja u FBiH, koeficijent determinacije ovog modela povećava se neznatno, sa 49,76 na 49,87, što predstavlja tek malo povećanje.

U kasnijem procesu, uključivanje informacija o prihodima iz provjerljivih izvora ne dovodi do efikasnijeg ciljanja u FBiH. U tabeli 19 prikazani su obuhvat i distribucija korisnika koji bi bili identifikovani formulom indirektnog imovinskog cenzusa koja pravi razliku između ruralnih i urbanih područja i uključuje prihode kao prediktor za ruralni model. U poređenju sa odgovarajućim ruralno/urbanim modelom indirektnog imovinskog cenzusa bez uključivanja prihoda (molimo pogledajte tabelu 12 radi poređenja), formula “indirektni imovinski cenzus plus prihodi” postiže neznatno manju grešku isključenja ako se cilja najsiromašnijih 20% populacije. Nasuprot tome, ako je cilj da se identifikuje najsiromašnijih 10% populacije, greška isključenja je čak i veća. Sljedstveno tome, izgleda da bi uključivanje prihoda iz provjerljivih izvora kao dodatnog kriterijuma u formuli nepotrebno otežalo proces ocjene, pošto kako izgleda ne bi pomoglo da se postignu bolji rezultati ciljanja.

Tabela 19. Obuhvat i distribucija korisnika novokalibriranog modela indirektnog indirektnog imovinskog cenzusa koji uključuje prihode iz provjerljivih izvora, zasnovani na odvajanju ruralnih i urbanih područja (sa podacima iz 2011.), različiti obim programa, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1), prije transfer, za FBiH

	I	II	III	IV	V	Ukupno	
Obuhvat (u %)							*Greška isključenja*
Obim programa: 10%	37,7	8,2	3,0	1,1	0,3	10,0	62,3
Obim programa: 15%	52,0	15,4	4,5	2,6	0,9	15,0	48,0
Obim programa; 20%	61,8	23,6	8,7	4,5	1,8	20,0	38,2
Distribucija (u %)							*Greška uključenja*
Obim programa: 10%	75,0	16,3	5,9	2,1	0,7	100,0	25,0
Obim programa: 15%	68,9	20,4	5,9	3,5	1,2	100,0	31,1
Obim programa: 20%	61,5	23,6	8,6	4,5	1,8	100,0	38,5

Napomena: Zavisna varijabla modela indirektnog indirektnog imovinskog cenzusa je logaritam mjesečne potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera budžetskih naknada za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Primijenjeni su ponderi za

uzorkovanje na individualnom nivou.

5.2 Indirektni imovinski cenzus nakon filtera

Cilj primjene filtera prije formule indirektnog imovinskog cenzusa je da se smanji greška uključenja i da se distribucija naknada dodatno pomjeri prema nižim kvantilama. Sljedstveno tome, uključivanje filtera načelno smanjuje obim programa. Filteri zasnovani na karakteristikama koje su češće među populacijom (npr. posjedovanje mobilnog telefona) logično dovode do drastičnijeg smanjenja obima programa nego oni koji koriste rijetko uočene karakteristike (npr. posjedovanje sekundarnog stana).

Da bismo ispitali efikasnost ovog metoda, primijenili smo različite filtere povrh predloženih urbanih/ruralnih formula indirektnog imovinskog cenzusa (vidjeti tabele 20-25). Odluka da se za ovu analizu upotrijebe urbani/ruralni modeli indirektnog imovinskog cenzusa zasnovana je na većoj efikasnosti koju su pokazali ovi modeli u registrovanju razlika u stilu života između ruralnih i urbanih područja (vidi odjeljak 3.2).

U svim slučajevima uočljivo je da primjena filtera koji se zasniva na tome da li domaćinstvo ima mobilni telefon znatno smanjuje obim programa, a da ne poboljšava efikasnost/učinkovitost ciljanja. Korištenje interneta kao filtera dovodi do neznatnog smanjena obima programa, što rezultira veoma ograničenim smanjenjem grešaka uključenja, ali izgleda da nema željeni širi efekat na distribuciju. Kada se neposjedovanje garaže ili automobila koristi kao kriterijum za kvalifikovane, obim programa se u većoj mjeri smanjuje; prema tome, distribucija korisnika u gornje tri kvantile se smanjuje i greška uključenja drastičnije opada. Međutim, u ovom slučaju, pošto se uvijek radi o kompromisu između greške uključenja i greške isključenja, greška isključenja se povećava.

Domaćinstva koja posjeduju sekundarni stan predstavljaju veoma mali dio ukupne populacije i načelno imaju viši ekonomski status. Stoga, i kad se svi koji pripadaju domaćinstvu koje ima sekundarni stan smatraju nekvalifikovanim za primanje socijalnih naknada, obim programa će se smanjiti samo za manje od pola procentnog poena (ova promjena je stoga jedva vidljiva u donjim tabelama). Uprkos ovoj minornoj promjeni obima programa, u FBiH se distribucija korisnika u najvišoj kvantili populacije vidljivo smanjila, a u RS se smanjio broj korisnika koji pripadaju četvrtoj kvantili. Stoga, mada greška uključenja ostaje bukvalno ista kao u osnovnom scenariju, primjena ovog filtera bi imala željeni efekat, i omogućila bi da se manje ljudi koji pripadaju višim kvantilama kvalifikuje za naknade.

Slučajevi domaćinstava koja su u posljednjoj godini kupila automobil snažno su vezani sa višim nivoom potrošnje. Stoga je ova varijabla već sa velikim koeficijentom uključena u sve modele indirektnog imovinskog cenzusa. Prema tome, korištenje ove varijable kao filtera neće uticati na efikasnost indirektnog imovinskog cenzusa.

Ova analiza još jednom ilustruje kompromise između greške isključenja i greške uključenja. Dodavanje filtera modelu indirektnog imovinskog cenzusa dovodi do smanjenja greške uključenja, što je načelno praćeno odgovarajućim smanjenjem obima programa, i kao posljedicu ima povećanje greške isključenja. Ipak, filter zasnovan na tome da li domaćinstvo ima sekundarni stan izgleda da doprinosi efikasnosti/učinkovitosti ciljanja dok samo marginalno umanjuje njenu djelotvornost. Primjenom ovog filtera isključuju se ljudi koji pripadaju na sam vrh distribucije potrošnje, a obim programa smanjuje se tek neznatno.

Tabela 20. Obuhvat i distribucija korisnika ruralnog/urbanog modela indirektnog imovinskog cenzusa nakon primjene različitih filtera, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za FBiH, obim programa od 10%.

	I	II	III	IV	V	Ukupno	
Obuhvat korisnika (u %)							*Greška isključenja*
Polazna vrijednost: IC bez filtera	37,9	8,7	2,7	0,7	0,3	10,0	62,1
Domaćinstvo ima internet konekciju	35,7	7,9	2,6	0,7	0,3	9,4	64,3
Domaćinstvo ima mobilni telefon	7,2	2,0	0,4	0,1	0,0	1,9	92,8
Domaćinstvo ima sekundarni stan	37,9	8,7	2,7	0,7	0,1	10,0	62,1
Domaćinstvo ima garažu	33,3	7,1	1,7	0,6	0,3	8,6	66,7
Domaćinstvo ima automobil	31,1	6,7	1,6	0,5	0,1	8,0	68,9
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	37,9	8,7	2,7	0,7	0,3	10,0	62,1
Distribucija korisnika (u %)							*Greška uključenja*
Polazna vrijednost: IC bez filtera	75,2	17,3	5,5	1,4	0,7	100,0	24,8
Domaćinstvo ima internet konekciju	75,5	16,8	5,5	1,4	0,7	100,0	24,5
Domaćinstvo ima mobilni telefon	74,4	20,4	4,4	0,7	0,0	100,0	25,6
Domaćinstvo ima sekundarni stan	75,6	17,4	5,5	1,4	0,2	100,0	24,4
Domaćinstvo ima garažu	77,5	16,6	3,9	1,3	0,8	100,0	22,6
Domaćinstvo ima automobil	77,8	16,8	4,0	1,2	0,2	100,0	22,2
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	75,2	17,3	5,5	1,4	0,7	100,0	24,8

Izvor: Proračuni autora na osnovi APD 2011. *Napomene:* Domaćinstvo se kvalifikuje ako (1) za nju ne važi dato filtersko pitanje, npr. da li posjeduje automobil i (2) izlazni rezultat po formuli indirektnog imovinskog cenzusa je ispod određenog praga. Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje za 33%. Koriste se ponderi za uzorkovanje na individualnom nivou.

Tabela 21. Obuhvat i distribucija korisnika ruralnog/urbanog modela indirektnog imovinskog cenzusa nakon primjene različitih filtera, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za FBiH, obim programa od 15%

	I	II	III	IV	V	Ukupno	
Obuhvat korisnika (u %)							*Greška isključenja*
Polazna vrijednost: IC bez filtera	51,4	15,4	4,9	2,9	0,9	15,0	48,7
Domaćinstvo ima internet konekciju	46,7	13,7	4,6	2,7	0,8	13,7	53,3
Domaćinstvo ima mobilni telefon	8,8	2,6	0,6	0,6	0,2	2,5	91,2
Domaćinstvo ima sekundarni stan	51,4	15,4	4,9	2,9	0,6	15,0	48,7
Domaćinstvo ima garažu	41,5	11,7	2,7	1,9	0,7	11,7	58,5
Domaćinstvo ima automobil	38,6	11,5	3,0	1,8	0,6	11,1	61,4
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	51,4	15,4	4,9	2,9	0,9	15,0	48,7
Distribucija korisnika (u %)							*Greška uključenja*
Polazna vrijednost: IC bez filtera	68,0	20,6	6,5	3,8	1,1	100,0	32,0
Domaćinstvo ima internet konekciju	68,1	20,1	6,7	4,0	1,1	100,0	31,9
Domaćinstvo ima mobilni telefon	69,3	20,2	4,9	4,3	1,2	100,0	30,7
Domaćinstvo ima sekundarni stan	68,3	20,6	6,5	3,8	0,8	100,0	31,8
Domaćinstvo ima garažu	70,9	20,1	4,6	3,3	1,1	100,0	29,1
Domaćinstvo ima automobil	69,6	20,7	5,4	3,2	1,1	100,0	30,4
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	68,0	20,6	6,5	3,8	1,1	100,0	32,0

Izvor: Proračuni autora na osnovi APD 2011. *Napomene:* Domaćinstvo se kvalifikuje ako (1) za nju ne važi dato filtersko pitanje, npr. da li posjeduje automobil i (2) izlazni rezultat po formuli indirektnog imovinskog cenzusa je ispod određenog praga. Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje za 33%. Koriste se ponderi za uzorkovanje na individualnom nivou.

Tabela 22. Obuhvat i distribucija korisnika ruralnog/urbanog modela indirektnog imovinskog cenzusa nakon primjene različitih filtera, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za FBiH, obim programa od 20%

	I	II	III	IV	V	Ukupno	
Obuhvat korisnika (u %)							*Greška isključenja*
Polazna vrijednost: IC bez filtera	61,6	24,1	8,6	4,4	1,5	20,0	38,4
Domaćinstvo ima internet konekciju	55,8	20,9	7,4	4,3	1,2	17,9	44,2
Domaćinstvo ima mobilni telefon	10,6	3,8	1,1	0,6	0,2	3,3	89,5
Domaćinstvo ima sekundarni stan	61,6	24,1	8,6	4,4	1,3	20,0	38,4
Domaćinstvo ima garažu	48,1	17,0	5,7	2,7	1,1	14,9	51,9
Domaćinstvo ima automobil	44,7	16,1	5,8	2,9	0,9	14,1	55,3
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	61,6	24,1	8,6	4,4	1,5	20,0	38,4
Distribucija korisnika (u %)							*Greška uključenja*
Polazna vrijednost: IC bez filtera	61,3	24,2	8,6	4,4	1,5	100,0	38,7
Domaćinstvo ima internet konekciju	62,2	23,4	8,3	4,8	1,3	100,0	37,8
Domaćinstvo ima mobilni telefon	64,9	23,3	6,5	3,9	1,4	100,0	35,1
Domaćinstvo ima sekundarni stan	61,4	24,2	8,6	4,4	1,3	100,0	38,6
Domaćinstvo ima garažu	64,4	22,9	7,6	3,7	1,4	100,0	35,6
Domaćinstvo ima automobil	63,4	23,0	8,3	4,1	1,3	100,0	36,6
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	61,3	24,2	8,6	4,4	1,5	100,0	38,7

Izvor: Proračuni autora na osnovi APD 2011. *Napomene:* Domaćinstvo se kvalifikuje ako (1) za nju ne važi dato filtersko pitanje, npr. da li posjeduje automobil i (2) izlazni rezultat po formuli indirektnog imovinskog cenzusa je ispod određenog praga. Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje za 33%. Koriste se ponderi za uzorkovanje na individualnom nivou.

Tabela 23. Obuhvat i distribucija korisnika ruralnog/urbanog modela indirektnog imovinskog cenzusa nakon primjene različitih filtera, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS, obim programa od 10%

	I	II	III	IV	V	Ukupno	
Obuhvat korisnika (u %)							*Greška isključenja*
Polazna vrijednost: IC bez filtera	38,1	7,0	3,7	1,6	0,5	10,1	61,9
Domaćinstvo ima internet konekciju	36,1	6,1	3,7	1,6	0,5	9,6	63,9
Domaćinstvo ima mobilni telefon	7,7	1,6	0,1	0,3	0,0	1,9	92,4
Domaćinstvo ima sekundarni stan	38,1	7,0	3,7	0,9	0,5	10,0	61,9
Domaćinstvo ima garažu	31,3	5,1	2,7	1,0	0,2	8,0	68,7
Domaćinstvo ima automobil	30,8	5,2	3,0	1,6	0,5	8,2	69,2
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	37,1	7,0	3,7	1,6	0,5	9,9	62,9
Distribucija korisnika (u %)							*Greška uključenja*
Polazna vrijednost: IC bez filtera	74,8	13,7	7,3	3,2	1,0	100,0	25,2
Domaćinstvo ima internet konekciju	75,1	12,7	7,7	3,3	1,1	100,0	24,9
Domaćinstvo ima mobilni telefon	79,7	16,5	0,7	3,1	0,0	100,0	20,3

Domaćinstvo ima sekundarni stan	75,9	13,9	7,4	1,7	1,0	100,0	24,1
Domaćinstvo ima garažu	77,5	12,6	6,8	2,5	0,6	100,0	22,5
Domaćinstvo ima automobil	74,8	12,8	7,4	3,9	1,2	100,0	25,2
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	74,3	14,0	7,4	3,2	1,0	100,0	25,7

Izvor: Proračuni autora na osnovi APD 2011. *Napomene:* Domaćinstvo se kvalifikuje ako (1) za nju ne važi dato filtersko pitanje, npr. da li posjeduje automobil i (2) izlazni rezultat po formuli indirektnog imovinskog cenzusa je ispod određenog praga. Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje za 33%. Koriste se ponderi za uzorkovanje na individualnom nivou.

Tabela 24. Obuhvat i distribucija korisnika ruralnog/urbanog modela indirektnog imovinskog cenzusa nakon primjene različitih filtera, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS, obim programa od 15%

	I	**II**	**III**	**IV**	**V**	**Ukupno**	
Obuhvat korisnika (u %)							*Greška isključenja*
Polazna vrijednost: IC bez filtera	47,8	18,0	7,3	2,6	0,9	15,3	52,2
Domaćinstvo ima internet konekciju	44,9	16,7	6,7	2,3	0,5	14,2	55,1
Domaćinstvo ima mobilni telefon	9,4	4,1	1,0	0,5	0,0	3,0	90,6
Domaćinstvo ima sekundarni stan	47,4	18,0	6,9	1,9	0,9	15,0	52,7
Domaćinstvo ima garažu	39,3	11,1	5,4	1,8	0,6	11,6	60,7
Domaćinstvo ima automobil	35,8	11,9	5,8	2,6	0,5	11,3	64,2
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	46,4	18,0	7,3	2,6	0,9	15,0	53,7
Distribucija korisnika (u %)							*Greška uključenja*
Polazna vrijednost: IC bez filtera	62,3	23,6	9,6	3,4	1,2	100,0	37,7
Domaćinstvo ima internet konekciju	62,9	23,6	9,5	3,3	0,7	100,0	37,1
Domaćinstvo ima mobilni telefon	62,3	27,6	6,7	3,4	0,0	100,0	37,7
Domaćinstvo ima sekundarni stan	63,0	24,1	9,2	2,5	1,2	100,0	37,0
Domaćinstvo ima garažu	67,4	19,1	9,3	3,1	1,0	100,0	32,6
Domaćinstvo ima automobil	63,2	21,1	10,2	4,6	0,9	100,0	36,8
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	61,5	24,1	9,8	3,5	1,2	100,0	38,5

Izvor: Proračuni autora na osnovi APD 2011. *Napomene:* Domaćinstvo se kvalifikuje ako (1) za nju ne važi dato filtersko pitanje, npr. da li posjeduje automobil i (2) izlazni rezultat po formuli indirektnog imovinskog cenzusa je ispod određenog praga. Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje za 33%. Koriste se ponderi za uzorkovanje na individualnom nivou.

Tabela 25. Obuhvat i distribucija korisnika ruralnog/urbanog modela indirektnog imovinskog cenzusa nakon primjene različitih filtera, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS, obim programa od 20%

	I	**II**	**III**	**IV**	**V**	**Ukupno**	
Obuhvat korisnika (u %)							*Greška isključenja*
Polazna vrijednost: IC bez filtera	56,5	27,3	11,5	5,4	1,5	20,4	43,5
Domaćinstvo ima internet konekciju	53,0	24,6	8,7	4,3	1,2	18,3	47,0
Domaćinstvo ima mobilni telefon	11,9	6,2	2,3	1,2	0,1	4,4	88,1
Domaćinstvo ima sekundarni stan	56,1	27,3	10,8	4,6	1,5	20,0	43,9
Domaćinstvo ima garažu	46,1	18,1	7,5	4,2	1,2	15,4	53,9
Domaćinstvo ima automobil	40,9	17,6	8,3	4,4	1,2	14,4	59,1
Domaćinstvo je kupilo nov ili	55,1	26,6	11,5	5,4	1,5	20,0	45,0

polovan automobil u zadnjih 12 mjeseci							
Distribucija korisnika (u %)							*Greška uključenja*
Polazna vrijednost: IC bez filtera	55,1	26,8	11,3	5,3	1,5	100,0	44,9
Domaćinstvo ima internet konekciju	57,6	27,0	9,5	4,7	1,3	100,0	42,4
Domaćinstvo ima mobilni telefon	54,4	28,7	10,5	5,7	0,7	100,0	45,6
Domaćinstvo ima sekundarni stan	55,8	27,4	10,7	4,6	1,5	100,0	44,3
Domaćinstvo ima garažu	59,6	23,6	9,7	5,5	1,6	100,0	40,4
Domaćinstvo ima automobil	56,4	24,5	11,4	6,1	1,6	100,0	43,6
Domaćinstvo je kupilo nov ili polovan automobil u zadnjih 12 mjeseci	54,9	26,7	11,5	5,4	1,5	100,0	45,1

Izvor: Proračuni autora na osnovi APD 2011. *Napomene:* Domaćinstvo se kvalifikuje ako (1) za nju ne važi dato filtersko pitanje, npr. da li posjeduje automobil i (2) izlazni rezultat po formuli indirektnog imovinskog cenzusa je ispod određenog praga. Kvantile potrošnje se zasnivaju na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje za 33%. Koriste se ponderi za uzorkovanje na individualnom nivou.

5.3 Izdaci za komunalije

Konačni način ciljanja budžetskih naknada na bazi imovinskog cenzusa ka siromašnim domaćinstvima je da se izdaci za komunalije upotrijebe kao zamjenski indikator blagostanja datog domaćinstva. Simulirana su dva mehanizma ciljanja: Prvo, identifikovali smo 10, 15 i 20% najsiromašnijih pojedinaca na osnovi mjesečnih izdataka po osobi za električnu energiju. Drugo, obavljena je i simulacija po osnovi izdataka po osobi i za električnu energiju i za vodovod/kanalizaciju. Eliminatorne vrijednosti za programe različitog obima prikazane su u tabeli 26.

Tabela 26. Eliminatorne vrijednosti (u KM) na osnovi procijenjenih prosječnih mjesečnih izdataka za električnu energiju za 2011, različiti obim programa, za FBiH i RS

Obim programa/eliminatorni iznos	**FBiH**	**RS**
Obim programa: 10%	7,62	8,06
Obim programa: 15%	8,62	9,16
Obim programa: 20%	9,65	9,95

Tabele 27 i 28 prikazuju obuhvat i distribuciju korisnika za tri različita obima programa, pri čemu su korisnici odabirani jedino po njihovim izdacima po osobi za mjesečne račune za električnu energiju. Rezultati efikasnosti mehanizma ciljanja koji je zasnovan na izdacima po osobi za električnu energiju i vodovod/kanalizaciju nisu ovdje prikazani, pošto je taj mehanizam dosljedno davao slabije rezultate nego jednostavniji metod koji je zasnovan samo na izdacima po osobi za električnu energiju. Umjesto toga, te podatke možete naći u dodatku (vidi tabele A 5 i A 6).

Tabela 27. Obuhvat i distribucija za ciljanje na osnovi procijenjenih prosječnih mjesečnih izdataka za električnu energiju, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1), prije transfera, za FBiH

	I	II	III	IV	V	Ukupno	
Obuhvat (u %)							*Greška isključenja*
Obim programa: 10%	26,9	13,1	5,5	2,3	2,2	10,0*	73,1
Obim programa: 15%	34,7	20,5	10,4	5,9	3,5	15,0*	65,3
Obim programa; 20%	43,7	26,1	14,7	10,0	5,5	20,0*	56,3
Distribucija (u %)							*Greška uključenja*
Obim programa: 10%	53,8	26,2	11,0	4,6	4,4	100,0	46,2
Obim programa: 15%	46,3	27,3	13,8	7,9	4,7	100,0	53,7
Obim programa: 20%	43,7	26,1	14,7	10,0	5,5	100,0	56,3

Izvor: Proračuni autora na osnovi APD 2011. *Napomene:* Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. *Obim programa može odstupati od 10, 15 ili 20% zbog korištenja podataka na nivou domaćinstava na koje su primijenjeni ponderi za individualno uzorkovanje.

Tabela 28. Obuhvat i distribucija za ciljanje na osnovi procijenjenih prosječnih mjesečnih izdataka za električnu energiju, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1), prije transfera, za RS

	I	II	III	IV	V	Ukupno	
Obuhvat (u %)							*Greška isključenja*
Obim programa: 10%	26,6	14,4	6,1	3,8	0,8	10,3*	73,4
Obim programa: 15%	37,5	21,5	10,3	4,8	3,0	15,4*	62,5
Obim programa; 20%	45,6	30,0	14,7	5,9	4,9	20,2*	54,4
Distribucija (u %)							*Greška uključenja*
Obim programa: 10%	51,4	27,9	11,8	7,4	1,5	100,0	48,6
Obim programa: 15%	48,5	28,0	13,4	6,3	3,9	100,0	51,5
Obim programa: 20%	44,9	29,8	14,6	5,9	4,8	100,0	55,1

Izvor: Proračuni autora na osnovi APD 2011. *Napomene:* Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. *Obim programa može odstupati od 10, 15 ili 20% zbog korištenja podataka na nivou domaćinstava na koje su primijenjeni ponderi za individualno uzorkovanje.

Ako pretpostavimo da je obim programa 10%, 27% najsiromašnije kvantile u FBiH i RS bio bi obuhvaćen. Ovo se poredi sa obuhvatom od 38% najsiromašnije kvantile u FBiH i RS koja bi se postigla najefikasnijim modelima indirektnog imovinskog cenzusa. Kad se radi o distribuciji korisnika, simulacije su pokazale da bi 54% korisnika identifikovanih u FBiH i 51% korisnika identifikovanih u RS pripadalo najsiromašnijoj kvantili, dok je ovaj procenat veći od 75% za najbolje modele indirektnog imovinskog cenzusa. Za program obima 20%, ako bi se primijenio mehanizam ciljanja zasnovan na izdacima za komunalije, obuhvat bi bio 44% u FBiH i čak 45% u RS. Ali opet, ovo treba uporediti sa 62% u FBiH i 57% u RS za najbolje modele indirektnog imovinskog cenzusa.

U načelu, ovaj mehanizam ciljanja funkcioniše neznatno bolje u RS nego u FBiH, gdje će korisnici biti koncentrisaniji u najnižoj kvantili distribucije naknada a biće obuhvaćeno više ljudi iz najsiromašnije kvantile. U poređenju sa modelima indirektnog imovinskog cenzusa za RS i FBiH, koji su znatno složeniji, ovaj jednostavni mehanizam funkcioniše vrlo dobro. Povrh toga, implementacija jednog ovakvog mehanizma mogla bi biti relativno laka i troškovno efikasna ako pretpostavimo da će svako domaćinstvo imati račune koji pokazuju njihove izdatke za električnu energiju.

6 Pregled rezultata i odabir modela za dalje simulacije

Ovaj izvještaj predstavlja nekoliko različitih metoda ciljanja budžetskih naknada za civilno stanovništvo i poredi njihovu efikasnost sa aspekta obuhvata i distribucije korisnika. Tabele 22 i 23 i grafikoni 1 - 4 sadrže sintezu efikasnosti svih mehanizama ciljanja koje smo razmatrali. Radi lakše prezentacije, ovaj uporedni pregled koncentriše se na obim programa i greške isključenja i uključenja za svaki od mehanizama ciljanja.

Formule procijenjenih indirektnih imovinskih cenzusa, zasnovane na odvojenim modelima za urbane i ruralne regione u dva entiteta, FBiH i RS, dali su najperspektivnije rezultate u pogledu obuhvata i distribucije korisnika (vidi tabele 29 i 30). Naime, prema simulacijama, i u FBiH i u RS, program obima 10% obuhvatio bi oko 37% najsiromašnije petine populacije, dok bi samo 25% svih korisnika bilo nepotrebno uključeno. Radi poređenja, sadašnji program budžetskih naknada za civilno stanovništvo u FBiH, obuhvata svega 14% najsiromašnije kvantile, dok 67% njegovih korisnika ne spade u najsiromašniju petinu populacije (vidi tabele 1 i 2, str. 11). U RS, 12% ukupne populacije trenutno prima budžetske naknade za civilno stanovništvo, obuhvat najsiromašnije kvantile je 21% a procenat pogrešno uključenih korisnika je čak 64% (vidi tabele 4 i 5, str. 12).

Uključivanje informacija o tome da li neko domaćinstvo prima prihode iz nekog provjerljivog izvora u modele indirektnog imovinskog cenzusa ne poboljšava efikasnost tih modela i stoga se smatra nepotrebnim. Konkretnije informacije o prihodima je teško potvrditi, pa se oni stoga smatraju nepouzdanim. Kad se na modele indirektnog imovinskog cenzusa primijene dodatni filteri, efikasnost/učinkovitost ciljanja se ne poboljšava značajno. Jedini filter koji se može smatrati poboljšanjem formula indirektnog imovinskog cenzusa je da li domaćinstvo posjeduje sekundarni stan. On doprinosi efikasnosti/učinkovitosti ciljanja a samo marginalno umanjuje njegovu djelotvornost. Primjenom ovog filtera isključuju se ljudi koji pripadaju na sam vrh distribucije potrošnje, a obim programa se smanjuje tek neznatno.

Predloženi urbani/ruralni modeli indirektnog imovinskog cenzusa registruju skup lako uočljivih karakteristika povezanih sa nivoom blagostanja domaćinstava, uzimajući u obzir razlike u stilu života između dva entiteta i između ruralnih i urbanih područja unutar svakog od entiteta. Kao što je prikazano u donjim tabelama, time postaju daleko najprecizniji metod ciljanja ljudi koji su u stanju potrebe.

I model zasnovan jedino na izdacima za električnu energiju pokazuje značajnu preciznost, s obzirom na svoju jednostavnost. Procjene ukazuju da bi program obima 10% ukupnog stanovništva obuhvatio 27% prvi kvantile u oba entiteta i sveo grešku uključenja do oko 46% u FBiH i 49% u RS. Prednost ovog metoda je u tome što, iako nije jednako precizan kao modeli indirektnog imovinskog cenzusa, on omogućava laganu provjeru kvalifikovanosti. Kandidati treba samo da pokažu svoj račune za električnu energiju da uđu u razmatranje za odobrenje naknada.

Analiza pokazuje da uključivanje filtera u postojeće mehanizme prihodovnog cenzusa ne može dovoljno poboljšati ciljanje. I mada se time smanjuje greška uključenja, filteri povećavaju grešku isključenja, koja je u sadašnjem obliku programa već vrlo visoka (oko 90%).

Grafikoni 1 i 2 jasno ilustruju kompromis između greške uključenja i greške isključenja. Dolje navedeni podaci takođe pokazuju da, logički, smanjenje obima programa dovodi do smanjenja greške uključenja i povećanja greške isključenja. Jedine opcije koje se mogu iskoristiti da se poboljša ciljanje sadašnjih naknada dodijeljenih na osnovi indirektnog

imovinskog cenzusa, iako tek neznatno, su da se smatra da domaćinstva koja imaju internet konekciju ili domaćinstva koja posjeduju automobil ne mogu da se kvalifikuju za naknade. Povrh toga, uvođenje različitih kategorija za ciljanje ne rezultira distribucijom naknada orijentisanom na siromašne zbog nepostojanja ili vrlo slabe korelacije između ovih kategorija i nivoa potrošnje. Prema tome, greška uključenja i greška isključenja procijenjene za različite kategorije ciljanja su znatno velike (vidjeti grafikone 3 i 4).

Iako postoji tendencija da procjene predloženih metoda ciljanja budu previsoke, pošto sve simulacije u ovoj analizi pretpostavljaju savršenu implementaciju, rezultati ukazuju da bi primjena ruralnog/urbanog modela indirektnog imovinskog cenzusa u praksi ili modela izdataka za električnu energiju znatno poboljšali ciljanje budžetskih naknada za civilno stanovništvo u Bosni i Hercegovini. Sljedstveno tome, očekuje se da bi ovo djelotvornije ciljanje programa dovelo do poboljšanja u smanjenju siromaštva i finansijskoj održivosti socijalne zaštite u zemlji.

Tabela 29. Pregled efikasnosti/učinkovitosti ciljanja simuliranih modela, za FBiH

Simulirani modeli	*Obim programa (u %)*	*Greška isključenja (u %)*	*Greška uključenja (u %)*
Modeli indirektnog imovinskog cenzusa			
Model indirektnog imovinskog cenzusa iz 2007. (sa podacima za 2011.), različit obim programa	10	66,7	33,5
	15	53,6	38,4
	20	43,1	43,3
Novokalibrirani model indirektnog imovinskog cenzusa zasnovan na ukupnoj populaciji (sa podacima za 2011.), različit obim programa	10	62,4	24,7
	15	50,0	33,3
	20	40,3	40,3
Novokalibrirani model indirektnog imovinskog cenzusa zasnovan na razdvajanju ruralnih i urbanih područja (sa podacima za 2011.), različit obim programa	10	62,1	24,8
	15	48,7	32,0
	20	38,4	38,7
Novokalibrirani model indirektnog imovinskog cenzusa sa prihodima zasnovan na razdvajanju ruralnih i urbanih područja (sa podacima za 2011.), različit obim programa	10	62,3	25,0
	15	48,0	31,1
	20	38,2	38,5
Model izdataka za komunalije			
Ciljanje zasnovano na izdacima za električnu energiju, različit obim programa	10	72,6	45,2
	15	63,3	53,5
	20	55,7	55,6

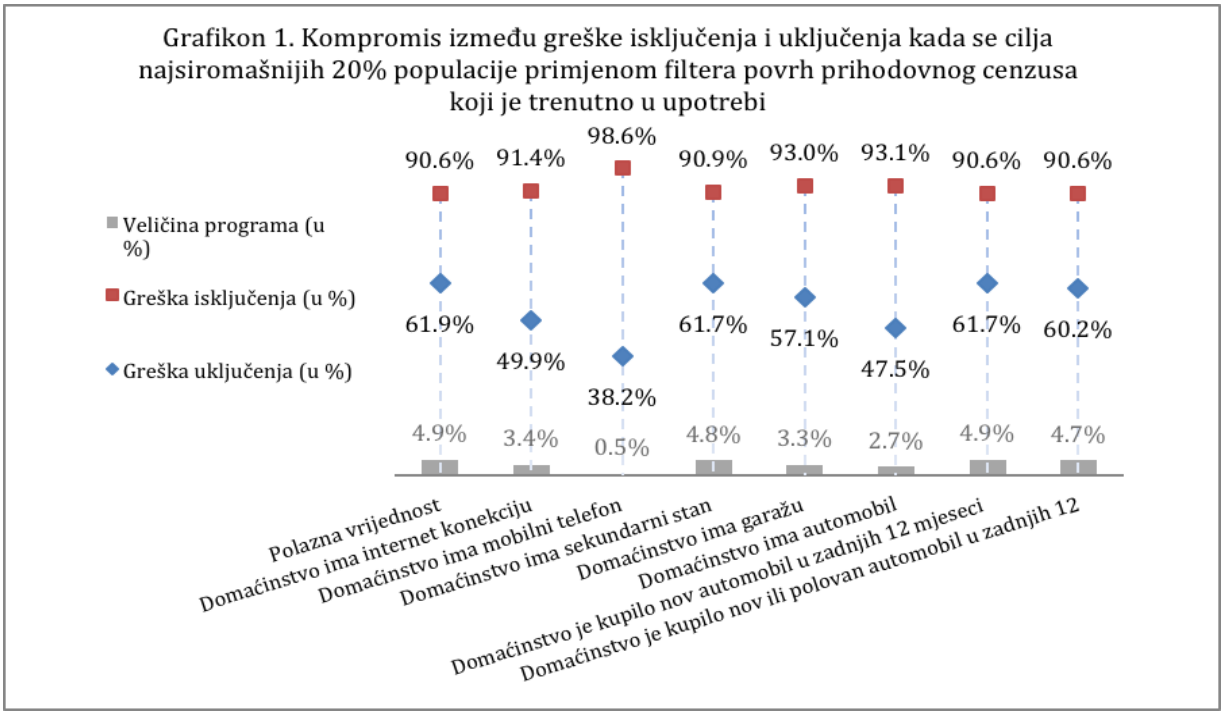
Izvor: Proračuni autora zasnovani na APD 2011. *Napomene:* Kvantile potrošnje koje su korištene za izračunavanje grešaka isključenja i uključenja zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1), prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou.

Tabela 30. Pregled efikasnosti/učinkovitosti ciljanja simuliranih modela, za RS

Simulirani modeli	*Obim programa (u %)*	*Greška isključenja (u %)*	*Greška uključenja (u %)*
Modeli indirektnog imovinskog cenzusa			
Model indirektnog imovinskog cenzusa iz 2007. (sa podacima za 2011.), različit obim programa	10	68,8	39,6
	15	58,1	45,5
	20	48,8	49,9
Novokalibrirani model indirektnog imovinskog cenzusa zasnovan na ukupnoj populaciji (sa podacima za 2011.), različit obim programa	10	66,7	34,6
	15	54,3	40,4
	20	44,8	46,0
Novokalibrirani model indirektnog imovinskog cenzusa zasnovan na razdvajanju ruralnih i urbanih područja (sa podacima za 2011.), različit obim programa	10	61,9	25,2
	15	52,2	37,7
	20	43,5	44,9
Model izdataka za komunalije			
Ciljanje zasnovano na izdacima za električnu energiju, različit obim programa	10	70,2	44,9
	15	61,4	50,0
	20	49,3	54,9

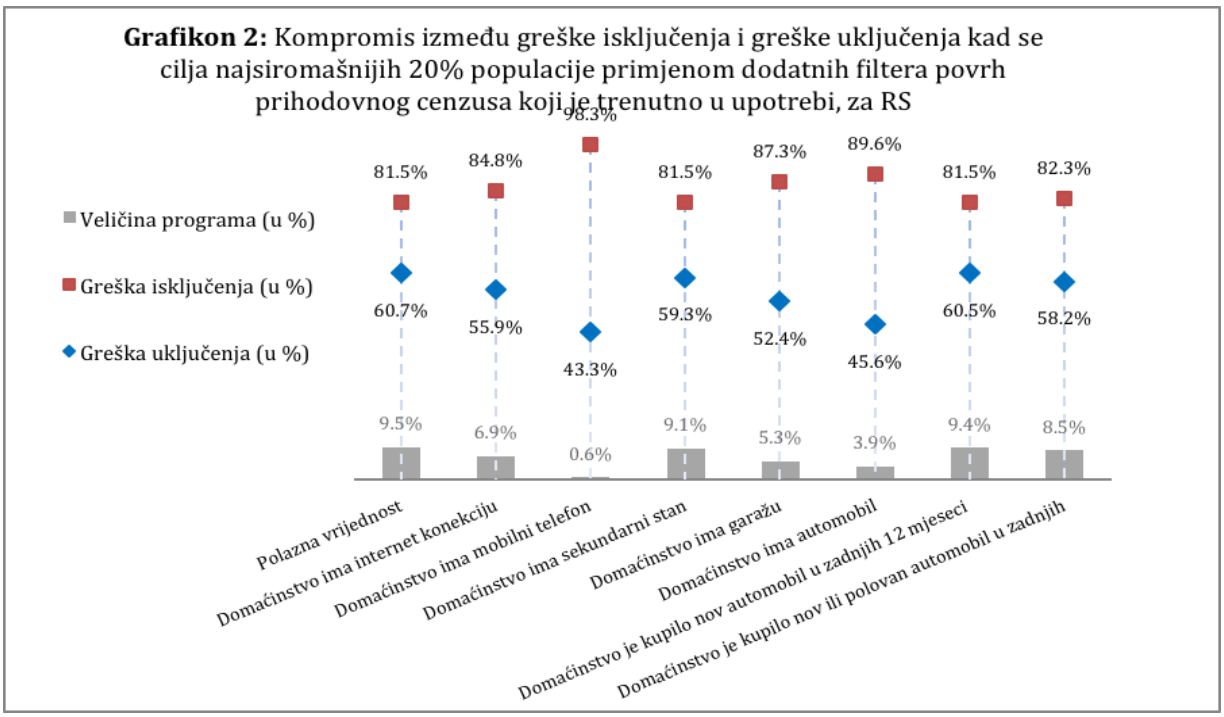
Izvor: Proračuni autora zasnovani na APD 2011. *Napomene:* Kvantile potrošnje koje su korištene za izračunavanje grešaka isključenja i uključenja zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1), prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou.

Grafikon 1. Kompromis između greške isključenja i greške uključenja kada se cilja najsiromašnijih 20% populacije primjenom dodatnih filtera povrh prihodovnog cenzusa koji je trenutno u upotrebi, za FBiH



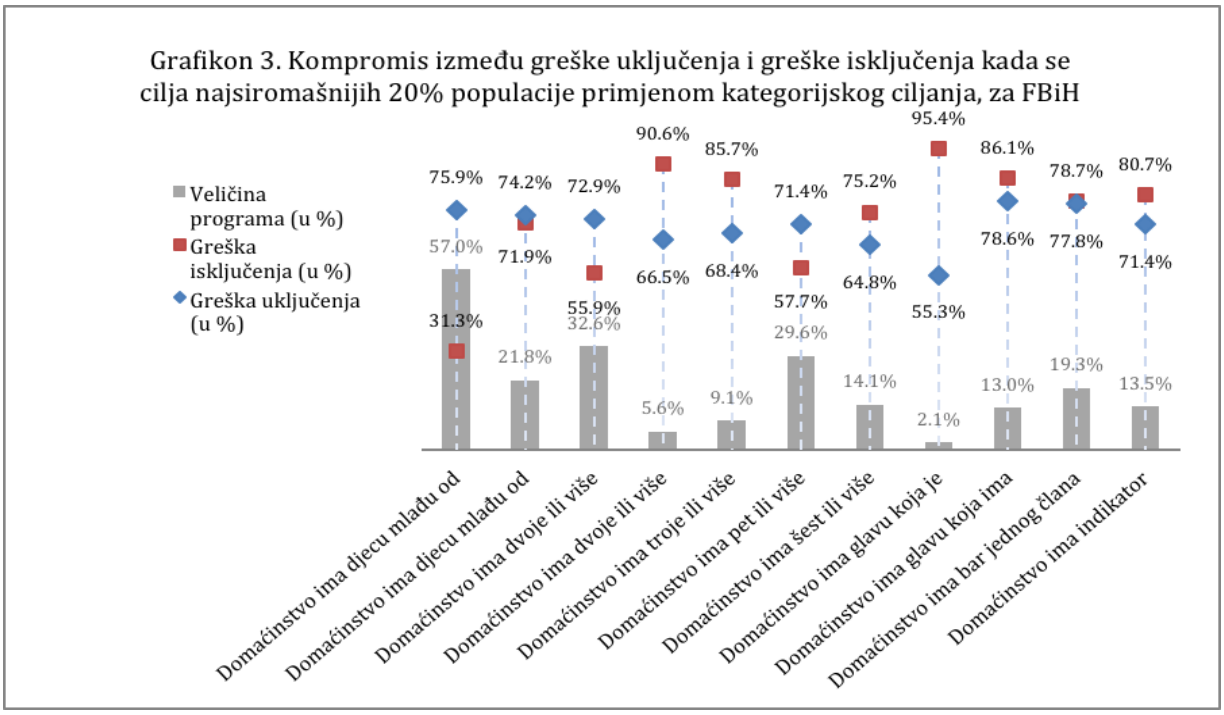
Izvor: Proračuni autora zasnovani na APD 2011. *Napomene:* Grafikon odgovara tabeli 15 u poglavlju 3.

Grafikon 2. Kompromis između greške isključenja i greške uključenja kada se cilja najsiromašnijih 20% populacije primjenom dodatnih filtera povrh prihodovnog cenzusa koji je trenutno u upotrebi, za RS



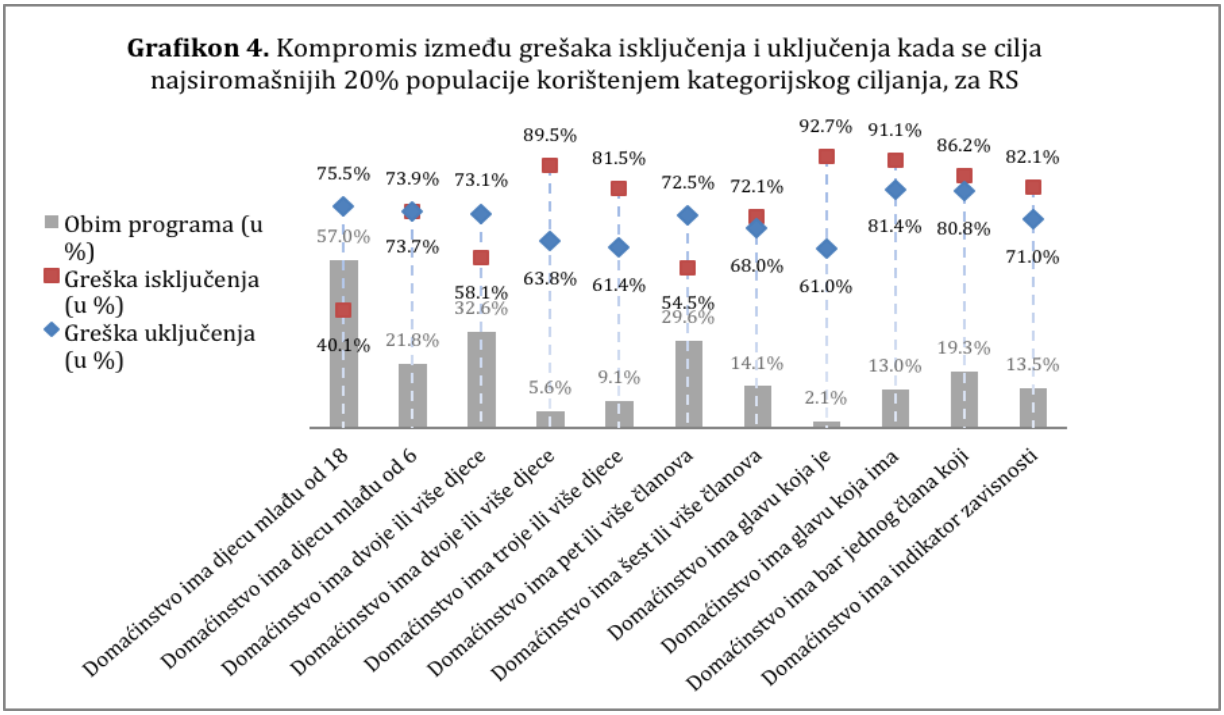
Izvor: Proračuni autora zasnovani na APD 2011. *Napomene:* Grafikon odgovara tabeli 16 u poglavlju 3.

Grafikon 3. Kompromis između greške isključenja i greške uključenja kad se cilja najsiromašnijih 20% populacije primjenom kategorijskog ciljanja, za FBiH



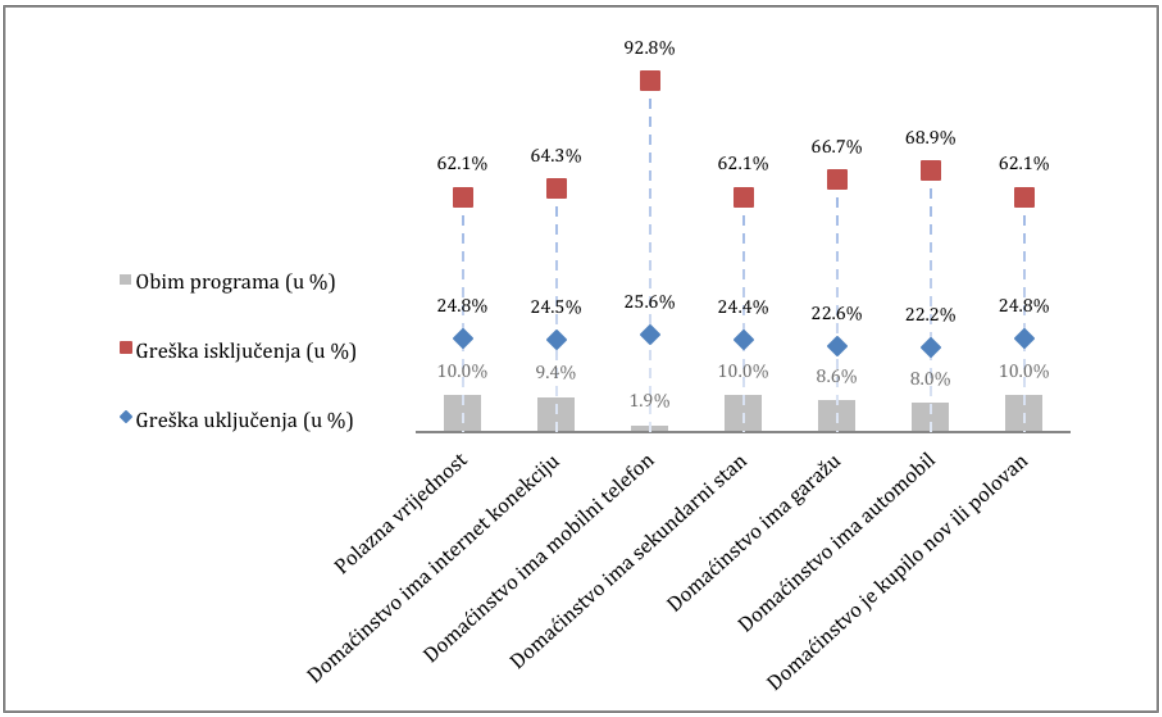
Izvor: Proračuni autora zasnovani na APD 2011. *Napomene:* Grafikon odgovara tabeli 17 u poglavlju 4.

Grafikon 4. Kompromis između grešaka isključenja i uključenja kada se cilja najsiromašnijih 20% populacije uz korištenje kategorijskog ciljanja, za RS



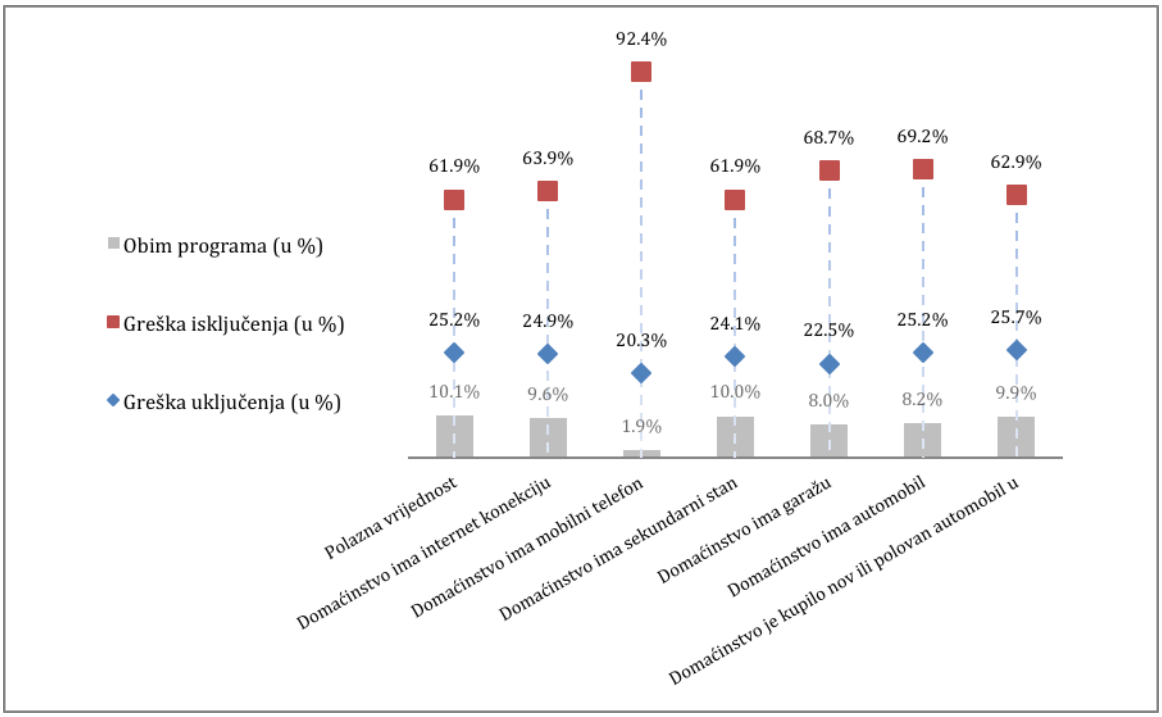
Izvor: Proračuni autora zasnovani na APD 2011. *Napomene:* Grafikon odgovara tabeli 18 u poglavlju 4.

Grafikon 5. Greška uključenja i isključenja kad se primjenjuju filteri povrh urbanog/ruralnog modela indirektnog imovinskog cenzusa, obim programa polazne osnove: 10%, za FBiH



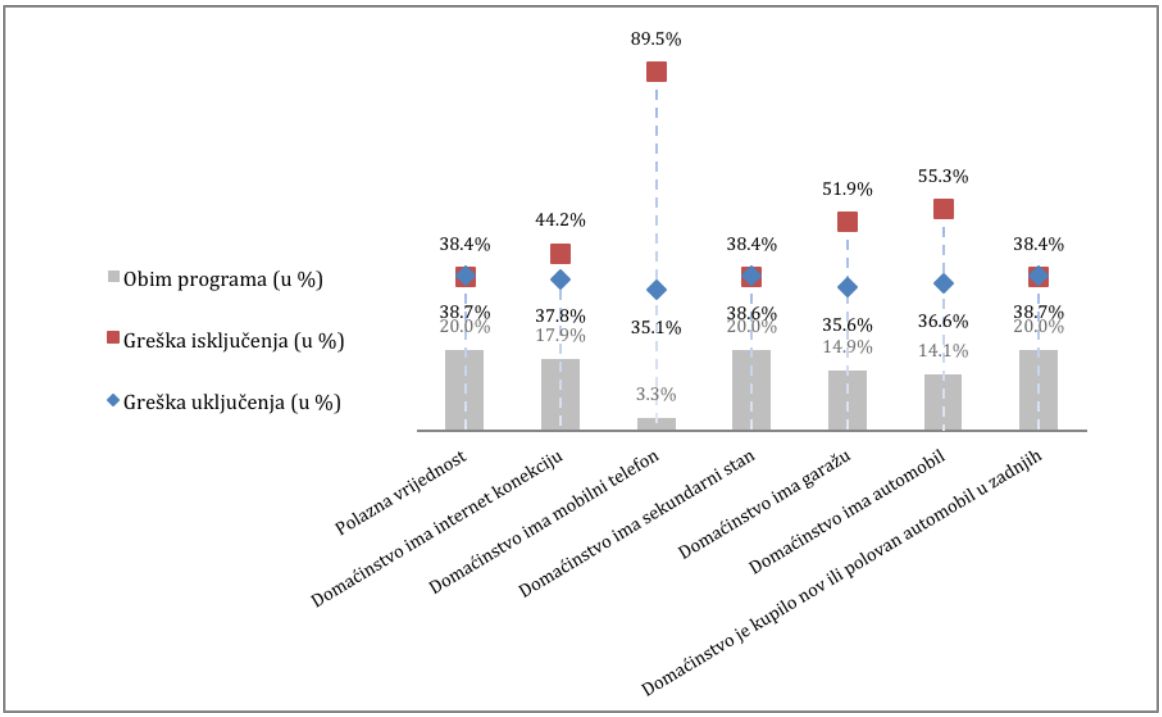
Izvor: Proračuni autora zasnovani na APD 2011. *Napomene:* Grafikon odgovara tabeli 20 u poglavlju 5.

Grafikon 6. Greška uključenja i isključenja kad se primjenjuju filteri povrh urbanog/ruralnog modela indirektnog imovinskog cenzusa, obim programa polazne osnove: 10%, za RS



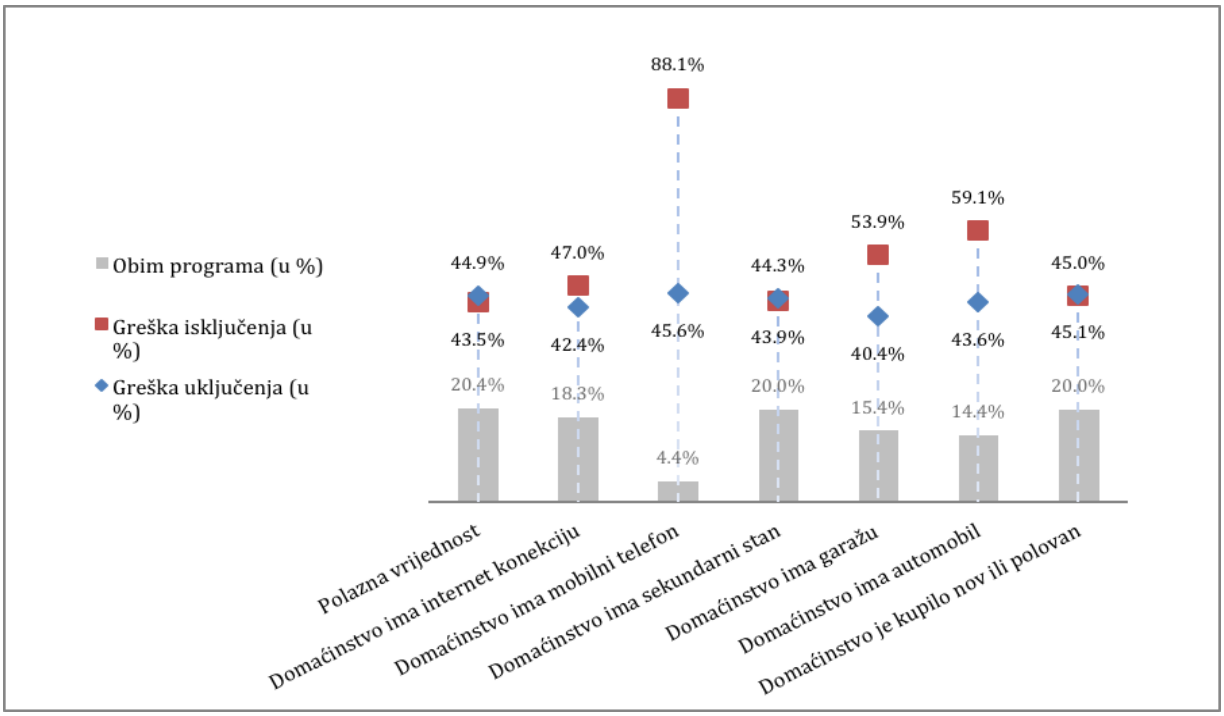
Izvor: Proračuni autora zasnovani na APD 2011. *Napomene:* Grafikon odgovara tabeli 23 u poglavlju 5.

Grafikon 7. Greška uključenja i isključenja kad se primjenjuju filteri povrh urbanog/ruralnog modela indirektnog imovinskog cenzusa, obim programa polazne osnove: 20%, za FBiH



Izvor: Proračuni autora zasnovani na APD 2011. *Napomene:* Grafikon odgovara tabeli 22 u poglavlju 5.

Grafikon 8. Greška uključenja i isključenja kad se primjenjuju filteri povrh urbanog/ruralnog modela indirektnog imovinskog cenzusa, obim programa polazne osnove: 20%, za RS



Izvor: Proračuni autora zasnovani na APD 2011. *Napomene:* Grafikon odgovara tabeli 25 u poglavlju 5.

7 Zaključci i preporuke za politike

Mreže socijalne zaštite namijenjene su ublaživanju siromaštva putem redistribucije i osiguranju osnovnog životnog standarda pojedinaca. U svojoj minimalnoj funkciji, one streme da ublaže ekstremno siromaštvo putem redistribucije i da osiguraju osnovne životne standarde za pojedince (MGSoG, 2013.). Precizno ciljanje naknada prema onima čije su potrebe najveće je suštinski bitno kad se teži ostvarenju ovog cilja na finansijski održiv način. Kad se uzme u obzir da Bosna i Hercegovina jedna od zemalja koje najviše troše na socijalnu zaštitu u regionu Evrope i Centralne Azije, ali istovremeno uspijeva da dosegne tek mali dio siromašnih, a njene naknade su u načelu regresivne, sadašnja efikasnost/učinkovitost ciljanja njenih socijalnih transfera je daleko od optimalne. Cilj ovog izvještaja je da se razviju alternativni mehanizmi ciljanja nebudžetskih naknada za civilno stanovništvo u Bosni i Hercegovini da bi došlo do poboljšanja efikasnosti/učinkovitosti ciljanja, pojačanog smanjenja siromaštva i pojačanih distributivnih efekata ovih socijalnih transfera.

Pošto je u Bosni i Hercegovini teško verifikovati prihode zbog velikog udjela neformalne ekonomije, jednostavni mehanizam prihodovnog cenzusa (PC) bio bi neadekvatan mehanizam ciljanja u ovoj zemlji. Umjesto toga, razmatrano je nekoliko drugih mehanizama koji koriste lako uočljive karakteristike domaćinstava kao zamjenski indikator za prihode domaćinstva, uključujući tu indirektne imovinske cenzuse, dodatne filtere za postojeće prihodovne cenzuse kategorijsko ciljanje i druge/hibridne forme ciljanja. Na osnovi postojeće statistike o raširenosti siromaštva u Bosni i Hercegovini, postavljen je cilj da se maksimiziraju poboljšanje blagostanja za najsiromašnijih 20% populacije. Povrh dopiranja do većeg dijela ove grupe, poboljšana efikasnost/učinkovitost ciljanja će, teoretski, rezultirati unapređenjem efikasnosti, što znači da bi trebalo i da se smanji broj domaćinstava koja su pogrešno obuhvaćena programom budžetskih naknada za civilno stanovništvo.

7.1 Postizanje ravnoteže između djelotvornosti i unapređenja efikasnosti

Gore opisani metodi ciljanja budžetskih novčanih transfera provjeravanih prihodovnim cenzusom u Bosni i Hercegovini ukazuju da novokalibrirani model indirektnog imovinskog cenzusa rezultira najefikasnijim ciljanjem kad se radi o identifikaciji najsiromašnijih 20% stanovništva. Kad se model zasnuje odvojeno na ruralnom i urbanom stanovništvu, efikasnost/učinkovitost ciljanja se dodatno poboljšava, što je posljedica činjenice da odvojeni modeli potrošnje za urbana i ruralna područja preciznije registruju različite uslove života u urbanim i ruralnim dijelovima entiteta. Ovo posebno važi za RS. Pored preciznijeg ciljanja, indirektni imovinski cenzus ima prednost da registruje višedimenzionalno siromaštvo umjesto da se fokusira na prihodovno siromaštvo.

Uprkos ovih prednosti, indirektni imovinski cenzus ima više nedostataka. Pored činjenice da je teško objasniti njegove kriterije za kvalifikaciju, pošto mogu izgledati proizvoljno, i da ih treba redovno podešavati zbog njihove osjetljivosti na manipulacije, kao i činjenice da je indirektni imovinski cenzus rigidan u smislu da ne može brzo da registruje ekonomske promjene, njegov najveći nedostatak je njegov administrativni teret. Prije svega, viši stepen preciznosti modela indirektnog imovinskog cenzusa načelno traži sofisticiraniji proces implementacije i shodno tome nosi više administrativne troškove.

Alternativa modelu indirektnog imovinskog cenzusa za RS, što bi bilo daleko manje zahtjevno u smislu administracije, bio bi model zasnovan na troškovima električne energije. Uprkos jednostavnoj formi, njegovo ciljanje je relativno precizno.

7.2 Implementacija novih modela

Problemi implementacije često nastaju zbog nedosljednosti u ključnim parametrima programa i zbog slabih sistema registracije. Rezultati mogu biti greške, prevare i duplikacija naknada unutar i među domaćinstvima. Da se osigura da implementacija datog programa socijalne zaštite, zasnovanog na predloženom mehanizmu ciljanja indirektnog imovinskog cenzusa, postiže rezultate približne onima simuliranim u ovom izvještaju, važno je da nadležne službe za isplatu naknada i sistemi registracije korisnika budu dobro organizovani (Svjetska banka, 2009, str. 36).

7.3 Naredni koraci

Samo na osnovu ovog izvještaja, nije moguće donijeti odluke o tačnoj formi novog metoda ciljanja za dodjelu budžetskih naknada u Bosni i Hercegovini. Kako je navedeno u Planu rada, odabir finalnih modela, koji će se koristiti za probe i dalje analize/simulacije, bit će obavljen nakon razgovora sa ključnim zainteresiranim stranama i nakon održavanja fokus grupa u FBiH i RS. Kada budu odabrani modeli koji nude najveće mogućnosti, posebna pažnja će se posvetiti analizi adekvatnosti naknada, što će biti prezentirano u slijedećem izvještaju.

Da bi programi socijalne zaštite bili djelotvorni, povrh ciljanja siromašnih, bitna je i adekvatnost naknada, što znači da nivo naknada treba da bude dovoljno visok da utiče na životni standard kvalifikovanih domaćinstava. U tom pogledu, potrebno je analizirati uticaj različitih potencijalnih programa i nivoa naknada na smanjenje siromaštva. Kako je navedeno u Projektnom zadatku i Planu rada, razvoj novih metoda ciljanja je proces, a ovaj izvještaj predstavlja drugi korak u tom smjeru (prvi korak bio je dokument “Ciljanje budžetskih novčanih transfera – Teorija i dokazi iz odabranih zemalja”).

Reference

Bierbaum, M. & Gassmann, F. (2013). *Non-contributory Cash Benefits for Social Protection in BiH – What Works and What Does Not (II): Targeting of non-contributory cash transfers – Theory and evidence from selected countries*. ("Budžetske novčane naknade za socijalnu zaštitu u BiH – Šta funkcioniše, a šta ne (II): Ciljanje budžetskih novčanih transfera – Teorija i dokazi iz odabranih zemalja") Maastricht: MGSoG.

Förster, M. & d'Ercole, M. (n.d.). *The oecd approach to measuring income distribution and poverty: strengths, limits and statistical issues*. Paris: OECD.

World Bank. (2009). *Targeting Performance and Poverty Impact of Social Benefits in Kazakhstan: Evidence from the 2007 Household Budget Survey*. Ovu bilješku pripremila je Svjetska banka kao dio aktivnosti tehničke pomoći u okviru projekta JERP TA, u 2009. fiskalnoj godini, mimeo.

Dodatak

Tabela A 1. Replikacija modela indirektnog imovinskog cenzusa iz 2007. godine sa podacima iz 2011. godine

	FBiH		RS	
Zavisna varijabla	*Log mjesečne potrošnje po osobi nakon transfera*	*Log mjesečne potrošnje po ekvivalentu odrasle osobe (OECD 1) prije transfera*	*Log mjesečne potrošnje po osobi nakon transfera*	*Log mjesečne potrošnje po ekvivalentu odrasle osobe (OECD 1) prije transfera*
Karakteristike domaćinstva				
Broj članova domaćinstva	-0,252***	-0,227***	-0,203***	-0,168***
	(0,01)	(0,01)	(0,01)	(0,01)
Broj djece mlađe od 14 godina	0,061***	0,107***	0,015	0,048***
	(0,02)	(0,02)	(0,02)	(0,02)
Broj djece od 14 do 24 godine	0,072***	0,065***	0,027*	0,012
	(0,02)	(0,01)	(0,02)	(0,02)
Nosilac domaćinstva: žena	0,039*	0,016		
	(0,02)	(0,02)		
Nosilac domaćinstva: postdiplomski stepen obrazovanja	0,156***	0,151***	0,096**	0,096**
	(0,03)	(0,03)	(0,04)	(0,04)
Nosilac domaćinstva: zaposlena (puno ili djelomično radno vrijeme)			-0,041	-0,016
			(0,03)	(0,03)
Broj zaposlenih članova domaćinstva (puno ili djelimično radno vrijeme)	0,095***	0,096***	0,048***	0,045***
	(0,01)	(0,01)	(0,01)	(0,01)
Karakteristike stana (zamjenske varijable)				
Stan ima kanalizacioni sistem	-0,127***	-0,122***		
	(0,02)	(0,02)		
Stan ima centralno grijanje	-0,200***	-0,204***		
	(0,03)	(0,03)		
Stan ima grijanje	0,091***	0,089***	0,040	0,043
	(0,02)	(0,02)	(0,10)	(0,09)
Stan koristi grijanje iz jednog grijnog tijela			-0,108	-0,113
			(0,10)	(0,09)
Stan ima unutrašnji toalet i kupatilo	0,096	0,086		
	(0,08)	(0,08)		
Stan ima balkon	0,057***	0,055***	0,033	0,032
	(0,02)	(0,02)	(0,02)	(0,02)
Stan je u stambenoj zgradi u kojoj živi više porodica			-0,144***	-0,141***
			(0,03)	(0,03)
Starost stana	0,001*	0,001		
	(0,00)	(0,00)		
Sekundarni stan	0,297***	0,289***	0,395***	0,382***
	(0,04)	(0,04)	(0,06)	(0,06)

Posjedovanje trajnih potrošnih dobara (zamjenske varijable)				
Telefon	0,123*** (0,02)	0,124*** (0,02)	0,084*** (0,02)	0,083*** (0,02)
Mašina za pranje veša	0,096** (0,04)	0,111** (0,04)	0,148*** (0,04)	0,165*** (0,04)
Šivaća mašina	0,111*** (0,02)	0,106*** (0,02)		
PC			0,083*** (0,03)	0,093*** (0,02)
Automobil	0,258*** (0,02)	0,270*** (0,02)	0,215*** (0,02)	0,225*** (0,02)
Električno ili plinsko kuhalo			0,065* (0,04)	0,069* (0,04)
Peć na drva ili ugalj	-0,102*** (0,03)	-0,102*** (0,03)		
Mašina za pranje posuđa	0,200*** (0,02)	0,203*** (0,02)	0,100*** (0,03)	0,085*** (0,03)
DVD ili video snimač	0,061*** (0,02)	0,076*** (0,02)		
HIFI sistem			0,029 (0,02)	0,035* (0,02)
Mobilni telefon	0,087*** (0,03)	0,129*** (0,03)	0,062** (0,03)	0,098*** (0,03)
Priuštivost odabranih izdataka				
Logaritam komunalnih izdataka[1]	0,260*** (0,02)	0,263*** (0,02)	0,185*** (0,02)	0,192*** (0,02)
Izvor prihoda (zamjenska varijabla)				
Bar jedan član domaćinstva ima prihod od penzije[2]	0,113*** (0,02)	0,092*** (0,02)		
Konstanta	5,094*** (0,11)	5,184*** (0,11)	5,492*** (0,12)	5,504*** (0,12)
Broj opservacija	4596	4595	2417	2360
Koeficijent determinacije	0,509	0,487	0,447	0,412

Izvor: Proračuni autora zasnovani na APD 2011.

Napomene: Zavisna varijable je prirodni logaritam mjesečne potrošnje po članu domaćinstva nakon transfera/prirodni logaritam mjesečne potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera budžetskih naknada za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou. Standardne greške u zagradama. * $p < 0.10$, ** $p < 0.05$, *** $p < 0.01$.

[1] U komunalne izdatke spadaju izdaci za električnu energiju, plin iz gradske mreže, centralno grijanje, vodovod i kanalizacioni sistem, te odvoz smeća.

[2] U penzione prihode spadaju starosna penzija, porodična penzija, radnoinvalidska penzija, inostrana penzija i boračka penzija.

Tabela A 2. Modeli potrošnje zasnovani na cjelokupnoj populaciji, ruralna i urbana područja, za FBiH

Zavisna varijable	*Cjelokupna populacija: Log mjesečne potrošnje po članu prije transfera*	*Ruralna područja: Log mjesečne potrošnje po ekvivalentu odrasle osobe (OECD 1) prije transfera*	*Urbana područja: Log mjesečne potrošnje po ekvivalentu odrasle osobe (OECD 1) prije transfera*
Karakteristike domaćinstva			
Log veličine domaćinstva	-0,578*** (0,03)	-0,560*** (0,04)	-0,606*** (0,05)
Broj djece mlađe od 18 godina			0,039*** (0,01)
Broj djece mlađe od 14 godina	0,059*** (0,01)		
Broj djece mlađe od 6 godina		0,031* (0,02)	
Broj djece od 6-13 godina		0,072*** (0,01)	
Starost nosioca domaćinstva	-0,001* (0,00)	-0,002** (0,00)	
Nosilac domaćinstva: Završeno srednje obrazovanje	0,097*** (0,02)	0,088*** (0,02)	0,138*** (0,03)
Nosilac domaćinstva: Viši stepeni obrazovanja	0,153*** (0,03)	0,144*** (0,03)	0,195*** (0,04)
Nosilac domaćinstva: Zaposlen (na stalni ugovor)	0,089*** (0,02)	0,079*** (0,02)	0,075*** (0,03)
Nosilac domaćinstva: Penzioner (starosna ili prijevremena penzija)	0,080*** (0,02)	0,095*** (0,02)	
Broj zaposlenih članova domaćinstva (puno ili djelomično radno vrijeme	0,061*** (0,01)	0,063*** (0,01)	0,049*** (0,02)
Karakteristike stambenog prostora			
Stan se nalazi u urbanom području	-0,043** (0,02)		
Glavni izvor vode za stan dovodi se cijevima u stan		0,108** (0,05)	
Stan uglavnom koristi vodu iz individualnog izvora (bunara, samostojeće cijevi…)		0,281*** (0,07)	
Stan ima unutarnji protočni toalet za isključivu upotrebu domaćinstva	0,045*** (0,02)		0,088*** (0,02)
Stan uglavnom koristi ugalj kao gorivo za grijanje		-0,138*** (0,05)	
Stan ima plinski bojler	0,160*** (0,04)		0,176*** (0,04)
Stan ima grijanje		0,070***	

		(0,03)	
Stan je individualna kuća ili dio kuće	-0,050**		-0,066**
	(0,02)		(0,03)
Stan ima garažu	0,085***	0,077***	0,082***
	(0,02)	(0,02)	(0,03)
Stan ima tavan	-0,036**	-0,042**	
	(0,02)	(0,02)	
Stan ima telefonsku liniju			0,080***
			(0,03)
Sekundarni stan	0,209***	0,294***	0,167***
	(0,04)	(0,07)	(0,04)
Starost stana			0,001*
			(0,00)
Broj osoba po jednoj sobi	-0,171***	-0,157***	-0,157***
	(0,02)	(0,03)	(0,05)
Pravni status stana: domaćinstvo je (zajednički) vlasnik (pa i ako kredit nije u potpunosti otplaćen)		0,087**	
		(0,04)	
Posjedovanje trajnih dobara			
Mašina za pranje posuđa	0,163***	0,181***	0,146***
	(0,02)	(0,02)	(0,03)
Mašina za pranje veša		0,080*	
		(0,05)	
Peć, grijač, bojler, “napa”	0,113***	0,127**	
	(0,04)	(0,05)	
Klima uređaj	0,062***		0,089***
	(0,02)		(0,03)
Mašina za šivanje ili pletenje	0,073***	0,129***	
	(0,02)	(0,03)	
Automobil, kupljen u zadnjih 12 mjeseci	0,515***	0,502***	0,609***
	(0,04)	(0,05)	(0,06)
Automobil, nije kupljen u zadnjih 12 mjeseci	0,231***	0,232***	0,235***
	(0,02)	(0,02)	(0,03)
Motocikl, skuter, moped	0,114**	0,155***	
	(0,04)	(0,04)	
Telefon	0,084***	0,081***	
	(0,02)	(0,02)	
Mobilni telefon	0,154***	0,140***	0,177***
	(0,02)	(0,03)	(0,03)
Faks	0,132**		
	(0,05)		
Satelitska antena	0,070***	0,078***	
	(0,02)	(0,02)	
DVD ili video snimač	0,059***	0,078***	
	(0,02)	(0,03)	
Internet konekcija	0,041**		0,076***

	(0,02)		(0,02)
Priključak kablovske TV	0,039**	0,051**	
	(0,02)	(0,02)	
Paket priključak	0,096***	0,063*	0,124***
	(0,03)	(0,04)	(0,04)
Priuštivost odabranih izdataka			
Log komunalnih izdataka[1]	0,199***	0,205***	0,190***
	(0,02)	(0,02)	(0,03)
Izvor prihoda (zamjenska varijabla)			
Bar jedan član domaćinstva prima boračku naknadu[2]	0,090***	0,108***	
	(0,03)	(0,03)	
Konstanta	5,617***	5,425***	5,702***
	(0,09)	(0,13)	(0,12)
Broj posmatranja	4604	2844	1743
Koeficijent determinacije	0,537	0,498	0,537

Izvor: Proračuni autora zasnovani na APD 2011.

Napomene: Zavisna varijable je prirodni logaritam mjesečne potrošnje po članu domaćinstva nakon transfera/prirodni logaritam mjesečne potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera budžetskih naknada za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou. Standardne greške u zagradama. * $p < 0.10$, ** $p < 0.05$, *** $p < 0.01$.

[1] U komunalne izdatke spadaju izdaci za električnu energiju, plin iz gradske mreže, centralno grijanje, vodovod i kanalizacioni sistem, te odvoz smeća.

[2] U boračke naknade spadaju invalidnine (vojna invalidnina), naknada za tuđu njegu i pomoć, porodična invalidnina, borački dodaci (u FBiH i RS) i naknade za demobilisane borce (FBiH).

Tabela A 3. Modeli potrošnje zasnovani na cjelokupnoj populaciji, ruralnim i urbanim područjima, za RS

Zavisna varijable	*Cjelokupna populacija: Log mjesečne potrošnje po članu prije transfera*	*Ruralna područja: Log mjesečne potrošnje po ekvivalentu odrasle osobe (OECD 1) prije transfera*	*Urbana područja: Log mjesečne potrošnje po ekvivalentu odrasle osobe (OECD 1) prije transfera*
Karakteristike domaćinstva			
Log veličine domaćinstva	-0,501***	-0,446***	-0,470***
	(0,03)	(0,04)	(0,05)
Broj djece mlađe od 14 godina	0,042***		0,057***
	(0,01)		(0,02)
Broj djece od 14 – 17 godina		0,044*	
		(0,02)	
Broj starih preko 65 godina		-0,045***	
		(0,02)	
Starost nosioca domaćinstva	-0,002*		
	(0,00)		
Nosilac domaćinstva: Završeno srednje obrazovanje	0,079***		0,213***
	(0,02)		(0,04)
Nosilac domaćinstva: Završen viši stepen obrazovanja	0,142***		0,279***
	(0,03)		(0,04)
Nosilac domaćinstva: Zaposlen (na stalnom ugovoru)	0,083***	0,068**	0,086**
	(0,02)	(0,03)	(0,04)
Nosilac domaćinstva: Penzioner (u starosnoj ili prijevremenoj penziji)	0,090***	0,089***	0,081**
	(0,03)	(0,03)	(0,03)
Nosilac domaćinstva: oženjen ili živi u zajednici / neformalnom braku	0,060**	0,072**	
	(0,02)	(0,03)	
Broj zaposlenih članova domaćinstva (puno ili djelimično radno vrijeme)	0,040***		0,077***
	(0,01)		(0,02)
Indikator zavisnosti: broj članova domaćinstva na jednog zaposlenog	-0,011*		-0,020*
	(0,01)		(0,01)
Karakteristike stambenog prostora			
Stan se nalazi u urbanom području	-0,062**		
	(0,02)		
Stan je u zgradi s više stanova / jedan od manje od 10 stanova u zgradi	0,084*		0,087*
	(0,05)		(0,05)
Stan ima grijanje	0,134***	0,253***	
	(0,03)	(0,04)	
Stan ima vrt	0,066***	0,104***	
	(0,02)	(0,04)	
Stan ima tavan	0,052***	0,071***	
	(0,02)	(0,03)	
Stan ima garažu		0,050*	

		(0,03)	
Telefonska linija		0,088***	
		(0,03)	
Sekundarni stan	0,337***		0,346***
	(0,05)		(0,07)
Starost stana			-0,002**
			(0,00)
Broj osoba po jednoj sobi	-0,130***	-0,106***	-0,173***
	(0,03)	(0,03)	(0,04)
Posjedovanje trajnih dobara			
Mašina za pranje veša	0,102**	0,105**	
	(0,04)	(0,04)	
Mašina za pranje posuđa			0,069**
			(0,03)
Peć, grijač, bojler, "napa"		0,089**	
		(0,04)	
Mašina za šivanje ili pletenje	0,081***	0,117***	
	(0,02)	(0,03)	
Internet konekcija	0,052**		
	(0,02)		
Oprema za čišćenje (usisivač za prašinu, aparat za pranje tepiha)	0,094**		
	(0,04)		
Automobil kupljen u posljednjih 12 mjeseci	0,452***	0,403***	0,566***
	(0,04)	(0,05)	(0,06)
Automobil kupljen prije najmanje 12 mjeseci	0,196***	0,190***	0,221***
	(0,02)	(0,03)	(0,03)
Motocikl, skuter, moped			0,100*
			(0,05)
Bicikl			0,051*
			(0,03)
Telefon	0,052**		
	(0,02)		
Mobilni telefon	0,136***	0,127***	0,146***
	(0,03)	(0,03)	(0,05)
TV priključak			0,055*
			(0,03)
Paket priključak	0,101***	0,222***	
	(0,04)	(0,06)	
Satelitska antena	0,116***	0,130***	0,096**
	(0,03)	(0,04)	(0,05)
DVD ili video snimač	0,056***	0,065**	
	(0,02)	(0,03)	
Priuštivost odabranih izdataka			
Log komunalnih izdataka[1]	0,212***	0,214***	0,179***
	(0,02)	(0,03)	(0,03)

Konstanta	5,359***	5,189***	5,672***
	(0,10)	(0,10)	(0,13)
Koeficijent determinacije	0,475	0,459	0,510
Broj posmatranja	2371	1458	913

Izvor: Proračuni autora zasnovani na APD 2011.

Napomene: Zavisna varijable je prirodni logaritam mjesečne potrošnje po članu domaćinstva nakon transfera/prirodni logaritam mjesečne potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera budžetskih naknada za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou. Standardne greške u zagradama. * $p < 0.10$, ** $p < 0.05$, *** $p < 0.01$.

[1] U komunalne izdatke spadaju izdaci za električnu energiju, plin iz gradske mreže, centralno grijanje, vodovod i kanalizacioni sistem, te odvoz smeća.

[2] U boračke naknade spadaju invalidnine (vojna invalidnina), naknada za tuđu njegu i pomoć, porodična invalidnina, borački dodaci (u FBiH i RS) i naknade za demobilisane borce (FBiH).

Tabela A 4. Indirektni imovinski cenzus uz uključenje prihoda, za ruralna područja FBiH

Zavisna varijabla	*Ruralna područja: Log mjesečne potrošnje po ekvivalentu odrasle osobe (OECD 1) prije transfera*
Karakteristike domaćinstva	
Log veličine domaćinstva	-0,539***
	(0,04)
Broj djece od 6-13 godina	0,066***
	(0,02)
Starost nosioca domaćinstva	-0,003***
	(0,00)
Nosilac domaćinstva: završeno srednje obrazovanje	0,077***
	(0,02)
Nosilac domaćinstva: završen viši stepen obrazovanja	0,135***
	(0,03)
Nosilac domaćinstva: zaposlen (na stalnom ugovoru)	0,064**
	(0,02)
Nosilac domaćinstva: je penzioner (u starosnoj ili prijevremenoj penziji)	0,096***
	(0,02)
Broj zaposlenih članova domaćinstva (puno ili djelimično radno vrijeme)	0,052***
	(0,01)
Karakteristike stambenog prostora	
Stan uglavnom koristi vodu iz individualnog izvora (bunara, samostojeće cijevi...)	0,275***
	(0,07)
Glavni izvor vode za stan dovodi se cijevima u stan	0,104**
	(0,05)
Stan ima grijanje	0,079***
	(0,03)
Gorivo uglavnom korišteno za grijanje: ugalj	-0,136***
	(0,05)
Stan ima garažu	0,077***
	(0,02)
Stan ima tavan	-0,045**
	(0,02)
Pravni status stana: domaćinstvo je (zajednički) vlasnik (pa i ako kredit nije u potpunosti otplaćen)	0,088**
	(0,04)
Broj osoba po jednoj sobi	-0,159***
	(0,03)
Posjedovanje trajnih dobara	
Mašina za šivanje ili pletenje	0,129***
	(0,03)
Mašina za pranje posuđa	0,186***
	(0,02)

Domaćinstvo posjeduje peć, grijač, bojler, “napu”	0,155*** (0,05)
Domaćinstvo koristi drugi apartman, kuću ili vikendicu povrh glavnog stana	0,308*** (0,08)
Domaćinstvo posjeduje automobil kupljen u posljednjih 12 mjeseci	0,510*** (0,05)
Domaćinstvo posjeduje automobil kupljen prije najmanje 12 mjeseci	0,234*** (0,02)
Domaćinstvo posjeduje motocikl, skuter ili moped	0,164*** (0,04)
Domaćinstvo posjeduje telefon (uporedi s modulom 6)	0,082*** (0,02)
Domaćinstvo posjeduje mobilni telefon	0,136*** (0,03)
Domaćinstvo ima priključak za kablovsku TV	0,047** (0,02)
Domaćinstvo posjeduje satelitsku antenu	0,078*** (0,02)
Domaćinstvo posjeduje DVD ili video snimač	0,079*** (0,03)
Priuštivost odabranih izdataka	
Log komunalnih izdataka[1]	0,208*** (0,02)
Izvor prihoda (zamjenska varijabla)	
Bar jedan član domaćinstva prima boračku naknadu[2]	0,105*** (0,03)
Bar jedan član domaćinstva prima prihod od zvaničnog lokalnog ili stranog poslodavca	0,047*** (0,02)
Konstanta	5,470*** (0,13)
Koeficijent determinacije	0,499
Broj posmatranja	2833

Izvor: Proračuni autora zasnovani na APD 2011.

Napomene: Zavisna varijable je prirodni logaritam mjesečne potrošnje po članu domaćinstva nakon transfera/prirodni logaritam mjesečne potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera budžetskih naknada za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. Primijenjeni su ponderi za uzorkovanje na individualnom nivou. Standardne greške u zagradama. * $p < 0.10$, ** $p < 0.05$, *** $p < 0.01$.

[1] U komunalne izdatke spadaju izdaci za električnu energiju, plin iz gradske mreže, centralno grijanje, vodovod i kanalizacioni sistem, te odvoz smeća.

[2] U boračke naknade spadaju invalidnine (vojna invalidnina), naknada za tuđu njegu i pomoć, porodična invalidnina, borački dodaci (u FBiH i RS) i naknade za demobilisane borce (FBiH).

Tabela A 5. Obuhvat i distribucija ciljanja zasnovana na izdacima za električnu energiju, vodovod i kanalizaciju, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za FBiH

	I	II	III	IV	V	Ukupno	
Obuhvat (u %)							*Greška isključenja*
Obim programa: 10%	26,1	12,3	6,8	3,1	1,8	10,0*	73,9
Obim programa: 15%	34,9	18,9	10,7	7,2	3,2	15,0*	65,1
Obim programa; 20%	44,1	25,6	16,4	9,3	4,6	20,0*	55,9
Distribucija (u %)							*Greška uključenja*
Obim programa: 10%	52,2	24,5	13,6	6,2	3,5	100,0	47,8
Obim programa: 15%	46,5	25,3	14,3	9,6	4,3	100,0	53,5
Obim programa: 20%	44,1	25,6	16,4	9,3	4,6	100,0	55,9

Izvor: Proračuni autora zasnovani na APD 2011. *Napomene:* Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. *Obim programa može odstupati od 10, 15 ili 20% zbog korištenja podataka sa nivoa domaćinstava na koje su primijenjeni ponderi za individualno uzorkovanje

Tabela A 6. Obuhvat i distribucija ciljanja zasnovana na izdacima za električnu energiju, vodovod i kanalizaciju, po kvantilama potrošnje po ekvivalentu odrasle osobe (skala OECD 1) prije transfera, za RS

	I	II	III	IV	V	Ukupno	
Obuhvat (u %)							*Greška isključenja*
Obim programa: 10%	26,8	14,0	5,3	3,7	1,0	10,2*	73,2
Obim programa: 15%	37,2	21,6	11,1	5,0	2,0	15,4*	62,8
Obim programa; 20%	45,0	27,1	15,9	8,4	5,0	20,3*	55,0
Distribucija (u %)							*Greška uključenja*
Obim programa: 10%	52,5	27,6	10,5	7,3	2,0	100,0	47,5
Obim programa: 15%	48,2	28,2	14,4	6,6	2,5	100,0	51,8
Obim programa: 20%	44,2	26,8	15,7	8,3	4,9	100,0	55,8

Izvor: Proračuni autora zasnovani na APD 2011. *Napomene:* Kvantile potrošnje zasnovane su na mjesečnoj potrošnji po ekvivalentu odrasle osobe (skala OECD 1) prije budžetskih novčanih transfera za civilno stanovništvo, uzimajući da je granična sklonost povećanju potrošnje 33%. *Obim programa može odstupati od 10, 15 ili 20% zbog korištenja podataka sa nivoa domaćinstava na koje su primijenjeni ponderi za individualno uzorkovanje

Tabela A 7. Spisak svih varijabli koje su inicijalno bile uključene u proces ocjenjivanja novokalibriranih modela indirektnog imovinskog cenzusa, cjelokupna populacija kao i urbani/ruralni modeli, FBiH i RS

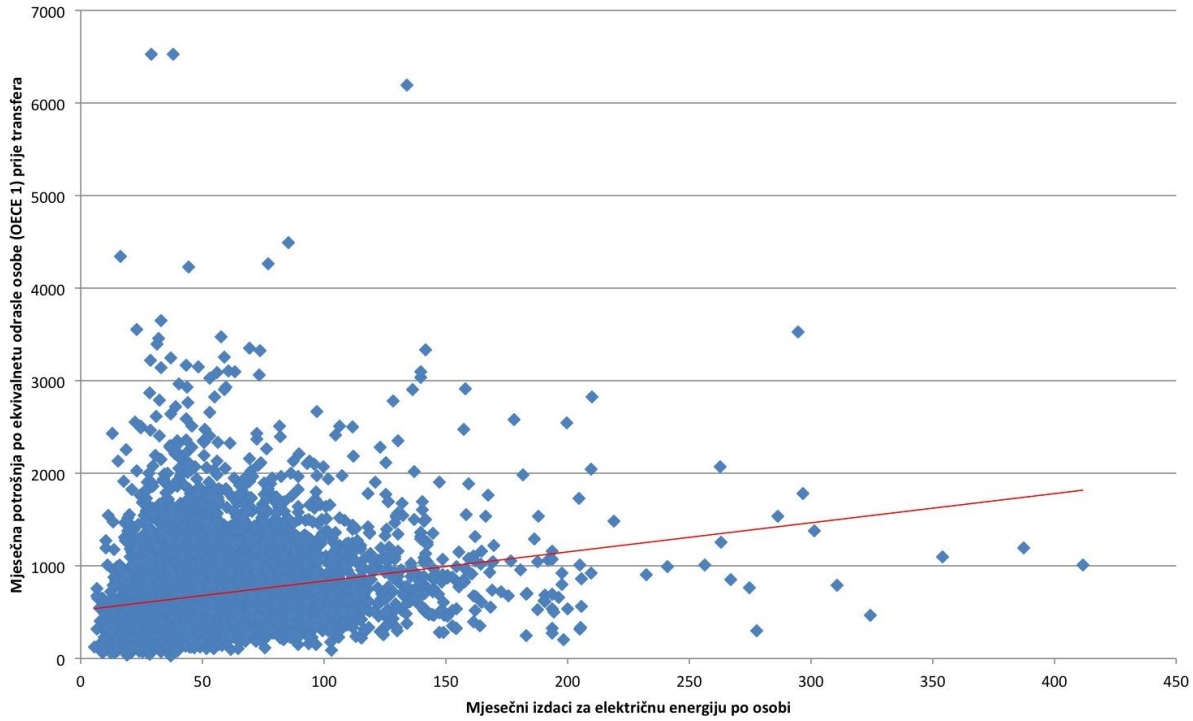
		FBiH			RS		
		Ukupno	*Urbano*	*Ruralno*	*Ukupno*	*Urbano*	*Ruralno*
	Tip	*stan.*			*stan.*		
Karakteristike domaćinstva							
Starost nosioca domaćinstva	Zamjenska	•	•	•	•	•	•
Nosilac domaćinstva je muškarac	Zamjenska	•	•	•	•	•	•
Nosilac domaćinstva ima stalno boravište u BiH	Zamjenska	•	•	•	•	•	•
Nosilac domaćinstva živi u neformalnom braku	Zamjenska	•	•	•	•	•	•
Nosilac domaćinstva je udovac/udovica	Zamjenska	•	•	•	•	•	•
Nosilac domaćinstva je završio/la srednje obrazovanje	Zamjenska	•	•	•	•	•	•
Nosilac domaćinstva ima viši stepen obrazovanja	Zamjenska	•	•	•	•	•	•
Nosilac domaćinstva je zaposlen/a po stalnom ugovoru	Zamjenska	•	•	•	•	•	•
Nosilac domaćinstva je za poslen/a po povremenom ili nekom drugom tipu ugovora[1]	Zamjenska	•	•	•	•	•	•
Nosilac domaćinstva je nezaposlen/a	Zamjenska	•	•	•	•	•	•
Nosilac domaćinstva je penzioner (u starosnoj ili prijevremenoj penziji)	Zamjenska	•	•	•	•	•	•
Nosilac domaćinstva ima zvanično rješenje o invaliditetu od komisije/zavoda	Zamjenska	•		•	•	•	
Logaritam veličine domaćinstva		•	•	•	•	•	•
Broj djece mlađih od 6 godina				•		•	•
Broj djece od 6-13 godina				•		•	•
Broj djece mlađih od 14 godina		•			•	•	
Broj djece u dobi od 14-17 godina		•		•	•	•	
Broj djece mlađe od 18 godina			•			•	•
Broj starih preko 65 godina		•	•	•	•	•	•
Broj penzionera (u starosnoj ili prijevremenoj penziji)		•	•	•	•	•	•
Broj zaposlenih članova domaćinstva (puno ili djelimično radno vrijeme)		•	•	•	•	•	•
Indikator zavisnosti: broj članova domaćinstva na jednog zaposlenog		•	•	•	•	•	•
Karakteristike stana							
Stan se nalazi u urbanom području	Zamjenska	•			•		
Stan je porodična kuća ili dio kuće	Zamjenska	•	•	•	•		•
Stan je dio objekta u kom živi više porodica u zgradi sa manje od 10 stanova	Zamjenska	•	•		•	•	•
Stan je dio objekta u kom živi više porodica u zgradi sa više od 10 stanova	Zamjenska	•	•			•	•
Starost stana		•	•	•	•	•	•
Broj osoba po jednoj sobi		•	•	•	•	•	•
Stan ima izdvojenu kuhinju	Zamjenska	•	•	•	•	•	•
Glavni izvor vode za stan se cijevima dovodi u stan	Zamjenska			•		•	•
Stan uglavnom koristi vodu iz individualnog izvora (bunar, samostojeća cijev...)	Zamjenska			•		•	•
Stan ima kanalizacioni sistem	Zamjenska		•			•	•

Stan ima unutrašnje kupatilo sa protočnim toaletom za kolektivnu upotrebu	Zamjenska	•				•	•
Stan ima unutrašnje kupatilo sa protočnim toaletom za vlastitu upotrebu	Zamjenska	•		•		•	•
Stan ima unutrašnji protočni toalet za vlastitu upotrebu	Zamjenska	•	•	•	•	•	•
Stan ima telefonsku liniju	Zamjenska	•	•	•	•		•
Stan ima garažu	Zamjenska	•	•	•	•	•	•
Stan ima podrum, šupu, kotlovnicu i sl.	Zamjenska	•	•	•	•	•	•
Stan ima tavan	Zamjenska	•	•	•	•	•	•
Stan ima balkon	Zamjenska	•	•	•	•	•	•
Stan ima baštu	Zamjenska	•	•	•	•	•	•
Stan ima grijanje	Zamjenska	•	•	•	•		•
Stan se grije jednim grijnim tijelom	Zamjenska					•	
Stan se grije preko toplane	Zamjenska					•	
Stan uglavnom koristi ugalj kao gorivo za grijanje	Zamjenska			•		•	•
Stan ima toplu vodu (na slavini)	Zamjenska	•		•	•		
Stan ima plinski bojler	Zamjenska	•	•			•	•
Pravni status stana: domaćinstvo je (zajednički) vlasnik (čak i ako stan nije u potpunosti otplaćen)	Zamjenska	•	•	•	•	•	•
Pravni status stana: Unajmljen na kraće ili duže vrijeme	Zamjenska	•	•		•	•	•
Povrh glavnog stana, domaćinstvo koristi još jedan stan, kuću ili vikendicu	Zamjenska	•	•	•	•	•	•
Posjedovanje trajnih dobara							
Domaćinstvo posjeduje električno/plinsko kuhalo	Zamjenska	•		•	•		
Domaćinstvo posjeduje peć na drva ili ugalj	Zamjenska	•	•	•	•	•	•
Domaćinstvo posjeduje mašinu za pranje posuđa	Zamjenska	•	•	•	•	•	•
Domaćinstvo posjeduje mašinu za pranje veša	Zamjenska	•	•	•	•	•	•
Domaćinstvo posjeduje opremu za čišćenje (usisivač za prašinu, aparat za čišćenje tepiha)	Zamjenska	•		•	•	•	
Domaćinstvo posjeduje peć, grijač, bojler, “napu”	Zamjenska	•	•	•	•		•
Domaćinstvo posjeduje klima uređaj	Zamjenska	•	•	•	•	•	•
Domaćinstvo posjeduje mašinu za šivanje ili pletenje	Zamjenska	•	•	•	•	•	•
Domaćinstvo posjeduje automobil kupljen u zadnjih 12 mjeseci	Zamjenska	•	•	•	•	•	•
Domaćinstvo posjeduje automobil koji nije kupljen u zadnjih 12 mjeseci	Zamjenska	•	•	•	•	•	•
Domaćinstvo posjeduje bicikl	Zamjenska	•	•	•	•	•	•
Domaćinstvo posjeduje motocikl, skuter, moped	Zamjenska	•		•	•	•	
Domaćinstvo posjeduje telefon (uporedi s modulom 6)	Zamjenska	•	•	•	•	•	•
Domaćinstvo posjeduje mobilni telefon	Zamjenska	•	•	•	•	•	•
Domaćinstvo posjeduje faks	Zamjenska	•	•			•	•
Domaćinstvo posjeduje satelitsku antenu	Zamjenska	•	•	•	•	•	•
Domaćinstvo posjeduje DVD ili video snimač	Zamjenska	•	•	•	•	•	•
Domaćinstvo posjeduje HiFi sistem (CD i MP3 plejer i sl.)	Zamjenska	•	•	•	•	•	•
Domaćinstvo ima internet konekciju	Zamjenska	•	•	•	•	•	•
Domaćinstvo ima priključak na kablovsku TV	Zamjenska	•	•	•	•	•	•
Domaćinstvo ima telefonski priključak	Zamjenska	•	•	•	•	•	•
Domaćinstvo ima konekcijski paket	Zamjenska	•	•	•	•	•	•

Priuštivost odabranih izdataka							
Log komunalnih izdataka[2]	Zamjenska	●	●	●	●	●	●
Izvor prihoda (zamjenska varijabla)							
Bar jedan član domaćinstva primio je penziju u posljednjih mjesec dana[3]	Zamjenska	●	●	●	●	●	●
Bar jedan član domaćinstva primio je borački dodatak u posljednjih mjesec danah[4]	Zamjenska	●	●	●			●

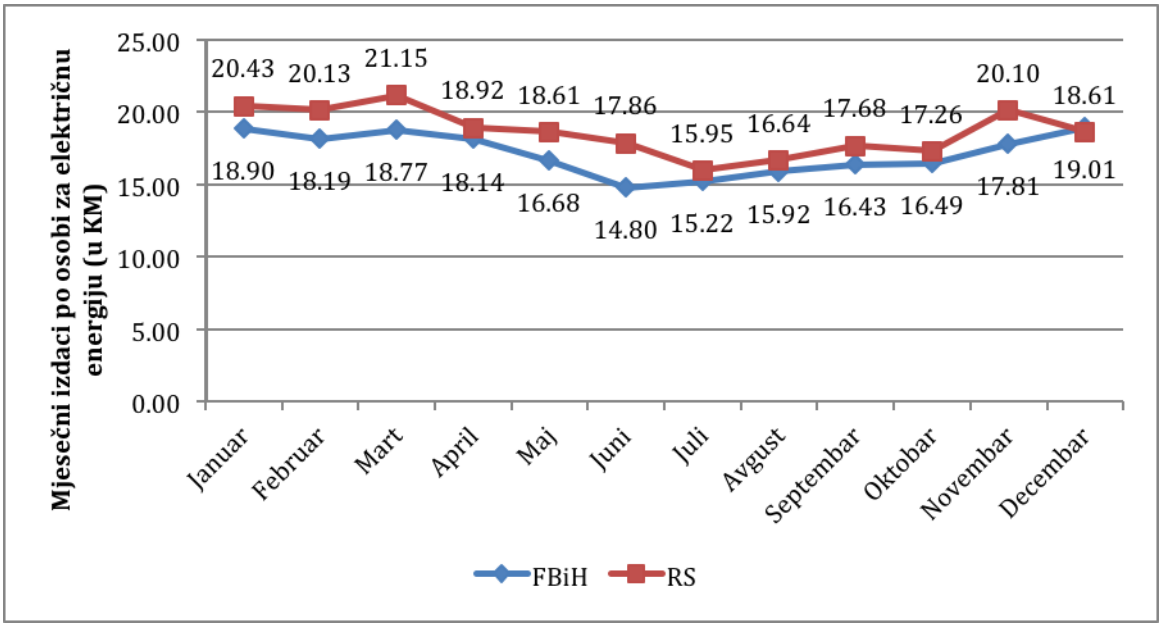
Napomene:
● Uključeno u inicijalni skup varijabli za stepenovanu ocjenu modela indirektnog imovinskog cenzusa
[1] Sezonski, pregovorno itd.
[2] Električna energija, plin, centralno grijanje, vodovod/kanalizacija, odvoz smeća.
[3] U penzione prihode spadaju starosna penzija porodična penzija, radnoinvalidska penzija, inostrana penzija i boračka penzija.
[4] U boračke naknada spadaju lične invalidnine (vojne invalidnine), dodatak za tuđu brigu i pomoć, porodične naknade, borački dodaci (u FBiH i RS), te naknade za demobilisane borce (FBiH).

Grafikon A 1. Odnos između izdataka na električnu energiju i potrošnje, 2011, za FBiH i RS



Izvor: Proračuni autora na osnovi APD 2011. *Napomena:* Mjesečna potrošnja po ekvivalentu odrasle osobe (skala OECD 1) prije transfera naknada za civilno stanovništvo zasniva se na pretpostavci da je granična sklonost povećanju potrošnje 33%.

Grafikon A 2. Mjesečne varijacije u prijavljenim izdacima za električnu energiju (u KM), za FBiH i RS



Izvor: Proračuni autora na osnovi APD 2011.