Budžetske novčane naknade za socijalnu zaštitu u BiH –
Šta funkcioniše, a šta ne (II):

# Ciljanje isplata budžetskih novčanih naknada - Teorija i iskustva iz odabranih zemalja

maj 2013.

*Sadržaj*

*Uvod* ..... *1*

*1 Mreže socijalne zaštite i ciljanje* ..... *1*

1.1 Argumentacija za razmatranje teme ciljanja u kontekstu mreža socijalne zaštite ..... 1
1.2 Metode ciljanja ..... 3
1.3 Mjerenje učinka ..... 8

*2 Indirektni imovinski cenzus* ..... *14*

2.1 Malo istorije ..... 14
2.2 Dizajn indirektnog imovinskog cenzusa ..... 14

*3 Implementacija PMT-a i drugi problemi u implementaciji* ..... *22*

3.1 Proces prikupljanja podataka ..... 23
3.2 Upravljanje informacionim sistemima ..... 26
3.3 Ažuriranje i recertifikacija ..... 27
3.4 Monitoring, verifikacija i suzbijanje prevara ..... 28
3.5 Mehanizmi za rješavanje žalbi i pritužbi ..... 29
3.6 Administrativni kapaciteti i institucionalne nadležnosti ..... 30
3.7 Transparentnost i troškovi ..... 31

*4 Zaključne primjedbe* ..... *34*

*Dodatak B: Opisi pojedinih zemalja* ..... *37*

Albanija ..... 37
Bugarska ..... 40

*Reference* ..... *44*

*Spisak grafikona*

Grafikon 1. Potrošnja na socijalnu pomoć (kao udio u BDP), po zemljama, 2008-09. ..... 2
Grafikon 2. LRSA: Obuhvat najsiromašnije kvintile (u %) ..... 9
Grafikon 3. LRSA: Preciznost ciljanja (procenat ukupnih naknada koji prima najsiromašnija kvintila (u %) ..... 9
Grafikon 4. LRSA: Naknade kao procenat potrošnje nakon transfera, po korisničkim domaćinstvima, za najsiromašniju kvintilu ..... 10
Grafikon 5. LRSA: Preciznost ciljanja, obuhvat i adekvatnost za najsiromašniju kvintilu ..... 11
Grafikon 6. Od populacije do korisnika: faze ciljanja ..... 23

*Spisak tabela*

Tabela 1. Pregled mehanizama ciljanja u odabranim zemljama ECA 6
Tabela 2. Matrica učinkovitosti ..... 8
Tabela 3. Administrativni troškovi ciljanja za odabrane prihodovne i indirektne imovinske programe, različite godine ..... 12
Tabela 4. Dvije metode za definisanje varijable i pondera za indirektni imovinski cenzus (PMT) ..... 16
Tabela 5. Tadžikistan: Rezultati bodovanja indikatora za PMT na osnovu "stepwise" regresije ..... 20
Tabela 6. Poređenje stvarnog i prognoziranog statusa siromaštva, Kirgiska Republika, 2005. 21
Tabela 7. Relativne prednosti različitih procesa prikupljanja podataka ..... 24
Tabela 8. Primjer modela s centralizovanim dizajnom i upravljanjem i decentralizovanim prikupljanjem podatak**a** ..... 30

Tabela A 1. Komparativni pregled prihodovnog, indirektnog imovinskog i hibridnog prihodovno-imovinskog cenzusa ..... 35

*Spisak tekstnih okvira*

Tekstni okvir 1. Verifikovani prihodovni cenzus i samo-ciljanje u Rumuniji……4
Tekstni okvir 2. Kategoričko ciljanje i indirektni imovinski cenzus u Kazahstanu ..... 5
Tekstni okvir 3. Horizontalna i vertikalna efikasnost ..... 8
Tekstni okvir 4. Garantovani minimalni prihod u odnosu na liniju siromaštva ..... 10
Tekstni okvir 5. Program garantovanog minimalnog prihoda u Bugarskoj ..... 11
Tekstni okvir 6. Kompromisi između greške uključenja i greške isključenja ..... 12
Tekstni okvir 7. FGT indikatori siromaštva i njihov uticaj na smanjenje siromaštva ..... 12
Tekstni okvir 8. Indirektni imovinski cenzus u Gruziji ..... 17
Tekstni okvir 9. Pilot za indirektni imovinski cenzus u Tadžikistanu ..... 19
Tekstni okvir 10. Greške u anketi ..... 22
Tekstni okvir 11. Registracija na zahtjev u Albaniji ..... 25
Tekstni okvir 12. Maksimalno trajanje prava na naknadu u Srbiji ..... 27

*Uvod*

Bosna i Hercegovina (BiH) se među zemljama istočne Evrope i centralne Azije (ECA) se ističe kao jedna od zemalja sa najvećom potrošnjom na programe socijalne pomoći. U periodu 2006-2008. godine, na socijalnu zaštitu trošilo se u prosjeku 4 procenta BDP, što je bilo više nego u svim zemljama u regiji, izuzev Hrvatske i uočljivo iznad prosjeka EU. Iz istorijskih razloga, znatan dio programa socijalne pomoći su programi zasnovani na pravima, za razliku od programa zasnovanih na potrebama, tj. kvalifikovanje se ne određuje po potrebama, već po stečenim pravima.

U kontekstu tekućeg projekta *"Razvoj, testiranje i preporuke za primjenu novih metodologija za ciljanje u raspodjeli novčanih naknada iz budžeta u Bosni i Hercegovini", ovaj izvještaj dopunjuje analizu iz materijala "Budžetske gotovinske naknade za socijalnu zaštitu u BiH - Šta funkcioniše, a šta ne?"* jer daje detaljan pregled metoda ciljanja u raspodjeli novčanih transfera iz budžeta zasnovan na iskustvima zemalja ECA i šire. Njegova namjena je da unaprijedi razumijevanje o razvoju novih modela ciljanja tokom implementacije projekta, pošto analiza tekuće situacije u BiH jasno ukazuje na potrebu za boljim ciljanjem civilnih naknada iz budžeta da se poboljša njihovo usmjeravanje i efekat smanjivanja siromaštva. Analiza se poziva i na iskustvo nekih zemalja Latinske Amerike u kojima su se indirektni imovinski cenzusi počeli razvijati početkom 80-tih godina.

U ovom izvještaju nudi se pregled postojećih praksi ciljanja raspodjele naknada u drugim zemljama regije ECA (i šire) i razrađuju se neke od ključnih lekcija koje treba savladati, a koje mogu biti zanimljive za razvoj alternativnog mehanizma ciljanja u BiH. Iako je fokus ovog izvještaja na indirektnom imovinskom cenzusu (Proxy-Means-Targeting - PMT), on počinje sa generalnim uvodom o ciljanju, izlaganjem argumentacije u prilog ovog pristupa, opisom različitih metoda ciljanja i načinima ocjenjivanja uspješnosti ciljanja u nekom sistemu. Drugo poglavlje se fokusira na PMT, razrađuje generalni kontekst u kome on funkcionira i opisuje potrebne korake za razradu modela. U nastavku, izvještaj se bavi ostalim aspektima relevantnim za implementaciju PMT-a. U čitavom izvještaju pozivamo se na iskustva drugih zemalja, bilo u tekstu ili u okvirnim tabelama. Za izvjestan broj zemalja više pojedinosti dato je u tekstnim okvirima i u dodatku.

Izvještaj su pripremile Franziska Gassmann, Esther Schüring, Sonila Tomini i Mira Bierbaum, konsultantkinje iz Maastricht Graduate School of Governance.

## *1 Mreže socijalne zaštite i ciljanje*

### *1.1 Argumentacija za razmatranje teme ciljanja u kontekstu mreža socijalne zaštite*

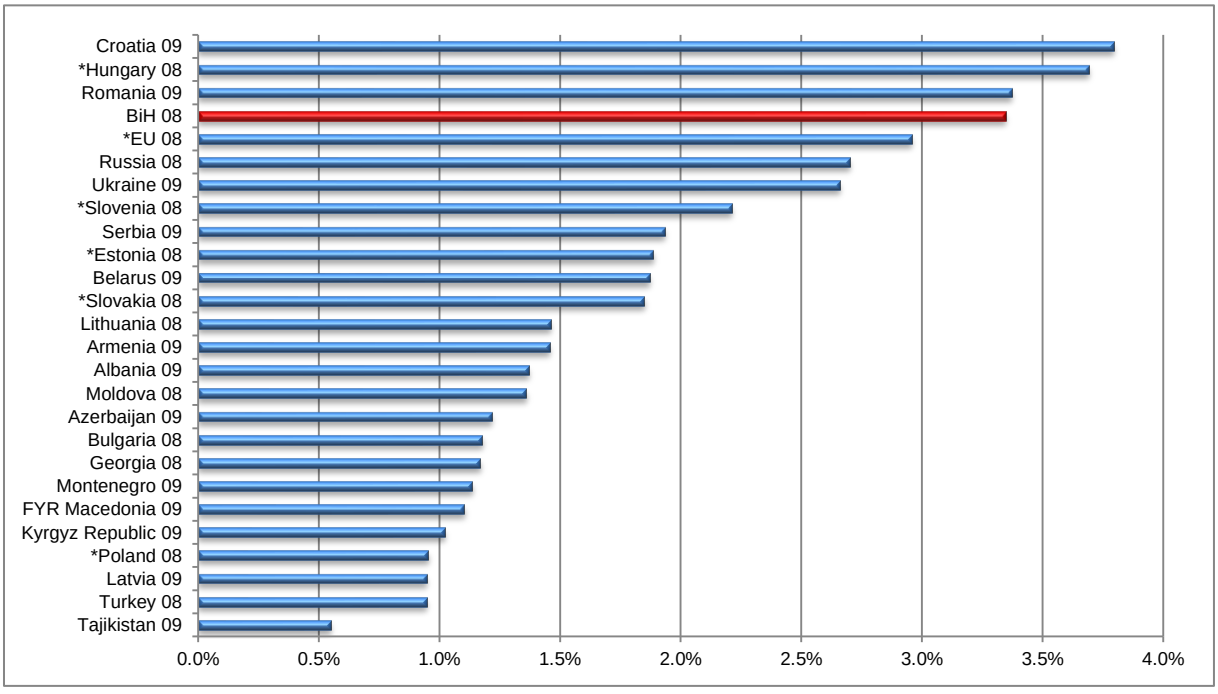
Globalna finansijska kriza je 2009. godine veoma teško pogodila region ECA. Te godine se BDP zemalja ECA u prosjeku smanjio za 5 procenata (Svjetska banka, 2012a), mada uz velike razlike između pojedinih zemalja s obzirom na stepen trgovinske integracije, finansijsku otvorenost i kretanja radne snage (Svjetska banka, 2010a). Nisu sve zemlje u regionu ECA uspjele da jednako adekvatno odgovore na udar ekonomske i finansijske krize,

ali mreže socijalne zaštite[1] su doprinijele da zaštite ljude od negativnih socijalnih efekata velike ekonomske recesije, posebno u zemljama u kojima su takvi sistemi već bili uspostavljeni prije nego što je kriza počela (Williams, Larrison, Strokova & Lindert, 2012.)

Uopšteno govoreći, mreže socijalne zaštite imaju nekoliko ciljeva. U svojoj minimalnoj funkciji, njihova svrha je da ublaže ekstremno siromaštvo putem redistribucije i predstavljaju posljednje sredstvo očuvanja osnovnog životnog standarda osoba u teškoj situaciji. Oni pomažu domaćinstvima da se u razumnoj mjeri nose s rizicima i da grade svoj život sa izvjesnom perspektivom, tj. da se izbjegne nedovoljno ulaganje u prehranu, obrazovanje i proizvodna sredstva. I na kraju, mreže socijalne zaštite su mehanizmi koji omogućavaju korisne reforme politika u drugim sektorima koje bi potencijalno mogle stvoriti visoke neposredne troškove za siromašna i ugrožena domaćinstva, u situaciji kad do poboljšanja socijalnog položaja dolazi sporije. (v. Grosh, del Ninno, Tesliuc & Ouerghi, 2008.).

Bukvalno sve zemlje u regionu ECA imaju neki vid mreža socijalne zaštite, ali ukupna potrošnja tih mreža mjerena kao udio u BDP date zemlje široko varira. Dok je prosječna potrošnja u regionu Evropske unije 3 procenta BDP, udio mreža socijalne zaštite se kreće od 0,6 procenata BDP u Tadžikistanu do skoro 4 procenta u Hrvatskoj i Mađarskoj (v. Grafikon 1). Ovo treba usporediti sa prosječnom potrošnjom na mreže socijalne zaštite od 1,9 procenata za 87 zemalja u razvoju za period 1996-2004. Kad se posmatraju trendovi po regionima, region ECA je drugi po veličini potrošnje nakon Bliskog istoka i sjeverne Afrike (u prosjeku 2,2 procenta), ali je ispred Latinske Amerike i Kariba (u prosjeku 1,3 procenta) (Weigand & Grosh, 2008.).[2]

**Grafikon 7.** Potrošnja na socijalnu pomoć (kao udio u BDP), po zemljama, 2008-09.




[1] Izraz sistemi socijalne zaštite odnosi se na "budžetske programe transfera koji su na neki način usmjeren na siromašne i one koji su postali ugroženi zbog siromaštva i šokova. Analogno američkom terminu "welfare" i evropskom izrazu "socijalna pomoć" (Svjetska banka, 2012a). U cijelom ovom pregledu literature, ovi izrazi se koriste naizmjence.

[2] Podsaharska Afrika nije obuhvaćena ovim poređenjem pošto mali broj opservacija u ovoj grupi zemalja rezultira manje robustnim prosjecima.

*Izvor:* Svjetska banka, "Social Expenditure Database 2011."

Pošto potražnja za mrežama socijalne pomoći može biti beskonačna, dok su resursi najvjerovatnije ograničeni, jedna opcija za najdjelotvornije i najefikasnije iskorištavanje ograničenog budžeta je da se transferi ciljano usmjeravaju najsiromašnijem segmentu stanovništva (Coady, Grosh & Hoddinott, 2004a). U većini zemalja ECA, kvalifikovanje za nedoprinosne programe transfera nije univerzalno, već je zasnovano na pravilima ciljanja koja bi trebalo da usmjere naknade jednoj potkategoriji stanovništva, u najvećem broju slučajeva siromašnima, ili barem dijelu siromašnih. Prema tome, ciljanjem se teži postići maksimalni obuhvat siromašnih, a i da se spriječi da nesiromašni "preotmu" naknade na štetu onih kojima su potrebne. To je način da se, u svjetlu ograničenih finansijskih resursa, poveća nivo naknada za siromašne, ili da se smanji pritisak na budžet uz očuvanje postojećih nivoa naknada (Grosh et al., 2008.).

Međutim, u poređenju sa univerzalnim programima obuhvata, ciljanje nosi dodatne troškove. Ono, na primjer, dovodi do viših administrativnih troškova, informacionih teškoća prilikom tačnog identifikovanja siromašnih i pada efikasnosti koji je rezultat odliva neciljanim grupama i neobuhvatanja ciljnih grupa (Atkinson, 1995, Sen, 1995.). Štaviše, političkoekonomske okolnosti utiču na to da, ako se budžet usvaja većinom glasova, ciljanje može umanjiti političku podršku za redistribuciju (Gelbach & Pritchett, 2002.). Učesnici u programu moraju snositi društvene posljedice, kao što je stigmatizacija. Ako pojedinci promijene svoje ponašanje kao reakciju na sistem transfera, ovo može dovesti do dodatnih troškova motivacije. Sve u svemu, pitanje razmjera ciljanja i izbor metoda ciljanja treba razmatrati u svjetlu konkretnog datog programa (Grosh et al., 2008, p. 86).

### *1.2 Metode ciljanja*

Različite opcije i kombinacije za ciljanu distribuciju socijalnih transfera najsiromašnijim i najugroženijim dijelovima stanovništva su razmatrane i većina se može naći bar u nekoj od zemalja u regionu ECA. Opšta klasifikacija prepoznaje ciljanje po kategorijama i po grupama, samoizbor i ciljanje zasnovano na individualnoj procjeni. Svaki od ovih metoda nosi konkretne prednosti i nedostatke i najpogodniji je u različitom kontekstu. Između ostalog, izbor pristupa u ciljanju određen je dostupnošću podataka, administrativnim kapacitetima i stepenom formalnog obuhvata u ekonomiji. Sve u svemu, mnogi programi koriste više mehanizama ciljanja.

Prvo, ciljanje po kategorijama ili grupama utvrđuje da li se pojedinac, domaćinstvo ili porodica kvalifikuje po karakteristikama kojima je teško manipulisati, koje se lako uočavaju i koje su u korelaciji sa siromaštvom. Kod **geografskog ciljanja**, kvalifikovanost se utvrđuje lokacijom domaćinstva, često na osnovu podataka sa mapa siromaštva. Mnogi pilot programi u svojoj početnoj fazi počinju u geografski izabranim ciljnim oblastima. **Demografsko ciljanje** se, *inter alia*, zasniva na starosnoj dobi, rodu ili invalidnosti, a najuobičajeniji programi su dječji dodatak i socijalne penzije. Ovi oblici naknada imaju prednost što su jednostavni i laki za administriranje, često su politički popularni i lako ih se može kombinovati sa drugim pristupima ciljanju. Ipak, njihova ograničena preciznost, koja dovodi do prelijevanja nesiromašnim korisnicima, izaziva zabrinutost, pa ovaj vid ciljanja pretpostavlja visoku korelaciju između demografskih i geografskih karakteristika i siromaštva.

Drugo, **samo-ciljanje** implicira da su ovakvi programi otvoreni za sve, ali očekuje se da će siromašni biti spremniji da se u njih uključe. U programima javnih radova ovo se postiže niskim nadnicama, a robne subvencije su usmjerene na hranu i robe koje neproporcionalno

mnogo konzumiraju siromašni. Proces samoizbora, pojednostavljuje administraciju i ne uzrokuje distorziju motivacija za rad. Štaviše, radni programi nose još i dodatnu vrijednost, npr. ako se koriste za unapređenje infrastrukture zemlje. Ipak, samo administriranje radova može biti složenije i teže. Štaviše, nisu svi oni koji pate od neimaštine u stanju da rade, a pored toga, ovi programi su ograničeni, a samim tim i broj potencijalnih učesnika. I naposlijetku, mali je broj roba čija je potrošnja, mjerena u apsolutnom iznosu, koncentrisana među siromašnim. Siromašni su skloni da generalno troše manje, što rezultira oblicima pomoći koji su samo neznatno progresivni, ili čak i regresivni. Sve u svemu, samo-ciljanje je uglavnom pogodno u situacijama hroničnog siromaštva ili kriza.

Treće, mehanizmi ciljanja koji se zasnivaju na individualnoj procjeni kandidata obuhvataju ciljanje u zajednici (community-based targeting - CBT), imovinski cenzus (means testing - MT), indirektni imovinski cenzus (proxy means testing - PMT) i hibridni imovinski cenzus (hybrid means testing - HMT). Komparativni prikaz posljednja tri spomenuta mehanizma ciljanja dat je u Tabeli A1. Kao što i sam naziv kaže, kod **ciljanja u zajednici**, zajednica je ta koja utvrđuje kvalifikovanost za pomoć. Logika je da se želi iskoristiti lokalno, često tačnije znanje o tome ko je zaista u stanju potrebe. Administrativni i troškovi monitoringa su relativno niski, s obzirom da se ovi poslovi obavljaju na lokalnom nivou. Međutim, postoji rizik da ovaj metod pod kontrolu stavi lokalna elita, te da se njime ojačaju postojeće strukture moći i obrasci isključivanja i podsticanja sukoba. Pored toga, teško je voditi monitoring na centralnom nivou. Ovi nedostaci čine ovaj instrument adekvatnim u kontekstima gdje je nivo naknada nizak, strukture zajednice dobro razvijene, a administrativni kapaciteti slabi.

Verifikovani **imovinski cenzus** smatra se zlatnim standardom ciljanja. Njime se prikupljaju bukvalno potpune informacije o svim izvorima prihoda i imovini nekog domaćinstva, a prikupljene informacije se provjeravaju potvrdama i poređenjem sa nezavisnim izvorima. Ako su prihodi ispod utvrđenog praga, smatra se da su pojedinac ili domaćinstvo kvalifikovani za transfer. Nije neuobičajeno da prihodovni cenzus ne bude nezavisno potvrđen ili da ih socijalni radnici obavljaju na "kvalitativan" način, pa su to tzv. jednostavni prihodovni cenzusi. Pod odgovarajućim okolnostima, prihodovni cenzusi su veoma precizni; posebno ako se primijeni neki oblik verifikacije. Štaviše, njima se brzo reaguje na prolazne promjene u socijalnom statusu, npr. u vrijeme ekonomske recesije. Međutim, one traže znatne administrativne kapacitete na svim nivoima ako se verifikacija radi ozbiljno, kao i detaljnu dokumentaciju ekonomskih transakcija. Stoga je dovoljan nivo zvaničnog obuhvata u ekonomiji neophodan preduslov. Pored toga, ovaj pristup sobom nosi potencijalno visoke privatne troškove za lica koja moraju pribavljati dokumente i potvrde i može proizvesti društveni trošak u vidu stigmatizacije i distorzije poticaja za rad.

**Tekstni okvir br. 1**. Verifikovani prihodovni cenzus i samo-ciljanje u Rumuniji[3]

Mreža socijalne pomoći u Rumuniji obuhvata novčane naknade, naknade u naturi kao i socijalne usluge. Gotovinske naknade mreže socijalne pomoći u Rumuniji sadrže pet glavnih stubova: 1) pomoć za djecu i porodicu, 2) pomoć za invalidnost i bolest, 3) komunalije za domaćinstvo, 4) podrška prihodima za krajnju nuždu (garantovani minimalni prihod - Guaranteed Minimum Income/GMI), i 5) naknade "za zasluge" (tj. potpore radnim veteranima, herojima itd.).

Program isplate garantovanog minimalnog prihoda (GMI) je glavni vid budžetske podrške prihodima u Rumuniji. Pristup ciljanju u distribuciji predstavlja kombinaciju verifikovanog

[3] Molimo pogledajte detaljniji opis u Dodatku.

imovinskog cenzusa i samo-ciljanja. Kontrolni mehanizmi obuhvataju administrativnu provjeru samodeklarisanih izjava o prihodima i verifikaciju imovinskog stanja putem obilaska domaćinstva na navedenoj adresi. Samo-ciljanje se postiže zahtjevom da sposobna lica moraju učestvovati u radu u zajednici. Zaposlenost člana porodice povećava nivo naknade za 15 procenata da bi se pojačao motiv za učešće na tržištu rada i time smanjila zavisnost od socijalne pomoći. (Svjetska banka, 2008.).

Ako su ekonomske aktivnosti u velikoj mjeri u neformalnoj ekonomiji, prihodi od formalnog rada, kao što su plate, vjerovatno će biti netačan pokazatelj socijalnog položaja datog domaćinstva. Pored toga, sezonske varijacije ili zarađivanje "u naturi" mogu otežati tačno mjerenje socijalnog statusa domaćinstava (Castañeda & Lindert, 2005, p. 23), što vodi prelijevanju socijalnih naknada nesiromašnim segmentima stanovništva. Argumentacija u prilog **indirektnog imovinskog cenzusa** je pribavljanje alternativnog indikatora za socijalni status domaćinstava. Rezultat za svako domaćinstvo ili pojedinca koji se prijavljuju za učešće u programu izračunava se na osnovu lako uočljivih karakteristika koje su povezane sa siromaštvom, kao što su lokacija i kvalitet stambene jedinice, sastav stambene jedinice, obrazovanje i zanimanje glave domaćinstva, ili posjedovanje trajnih roba. Tačna formula za bodovanje i odgovarajući prag za učešće u programu obično se izvode iz anketa domaćinstava. Korištenje lako uočljivih karakteristika umjesto zvaničnih dokumenata o prihodima ili drugoj imovini čini ovaj metod podesnim za kontekst zemalja u kojima je prisutan veliki nivo neformalnosti u ekonomiji.

**Tekstni okvir 2.** Kategoričko ciljanje i indirektni imovinski cenzus u Kazahstanu

Budžetski finansirana socijalna zaštita u Kazahstanu obuhvata niz raznih novčanih transfera, od kojih su neki kategorijski, a drugi zavise od prihoda domaćinstva: ciljani socijalni dodatak (Targeted Social Allowance - TSA), socijalni dodatak (Social Allowance - SAC), specijalni državni dodatak (Special State Allowance - SSA) i stambeni dodatak (Housing Allowance - HA) (Gassman, 2011a). TSA je transfer koji se odobrava na osnovi provjere imovinskog stanja. 2007. godine dobijalo ga je manje od jednog procenta stanovništva, a samo 3 procenta u najsiromašnijoj kvintili. Sedamdeset i dva procenta transfera distribuiraju se među najsiromašnijih 20 procenata. I mada se TSA isplaćuje samo vrlo malom broju domaćinstava, on u prosjeku čini 10 procenata budžeta domaćinstava porodica koje ga primaju ali nije imao gotovo nikakav mjerljiv učinak na siromaštvo (Svjetska banka, 2009a).

Pored programa socijalne pomoći koji vodi Vlada, Fondacija BOTA, koju su 2008. osnovali IREX i Save the Children, pomaže djeci i njihovim porodicama ulaganjima u zdravstvo, obrazovanje i socijalnu zaštitu. Ona nudi uslovne novčane transfere, socijalne usluge i pomoć za školarinu. Program uslovnih novčanih transfera (Conditional Cash Transfer Program - CCT) Fondacije BOTA obezbjeđuje redovne novčane transfere s namjerom da poboljša život siromašne djece. Program je počeo da se provodi u decembru 2009. u dva regiona. Ciljanje se zasniva na kombinaciji kategoričkog ciljanja i indirektnog imovinskog cenzusa, a korisnici moraju ispuniti niz uslova čiji je cilj da se popravi njihov zdravstveni i obrazovni status. Kvalifikovani korisnici su djeca u dobi od 4 do 6 godina do polaska u školu, trudnice i dojilje, djeca sa posebnim potrebama do dobi od 16 godina i adolescenti u dobi od 16-19 godina koji su završili školu. Nivo siromaštva domaćinstva lica koje se kvalifikuje utvrđuje se indirektnim imovinskim cenzusom. Pošto BOTA djeluje samo u nekoliko oblasti, ovaj sistem uključujuje i dimenziju geografskog ciljanja. U aprilu 2013. godine, BOTA je djelovala u šest oblasti i obezbjeđivala CCT za 56.000 korisnika (www.bota.kz). Pokazatelji i

rezultati za PMT se izvode iz Ankete o potrošnji domaćinstava za Kazahstan. Nedavna analiza koju je proveo OPM (2012.) ukazuje da je PMT djelotvoran u identifikovanju siromašnih domaćinstava. Sve u svemu, program je progresivan. Štaviše, kandidati doživljavaju kompjuterizovani proces ocjenjivanja (kandidati za učešće u programu dobijaju odgovor odmah) kao nepristran i kao takav on jača kredibilitet ovog programa.

Provođenje indirektnog imovinskog cenzusa je administrativno zahtjevno i teži da bude manje precizno nego verifikovani prihodovni cenzus, pošto je određeni stepen prelijevanja svojstven ovoj metodologiji. Ona slabije reaguje na iznenadne promjene ekonomskog položaja domaćinstava, pošto se većina posmatranih karakteristika odnosi na varijable stanja (npr. obrazovanje glave domaćinstva, posjedovanje trajnih dobara), a ne na tokove (npr. prihode). Pored toga, siromaštvo mora biti u dovoljnoj korelaciji sa više ovih indikatora. Utvrđivanje formule za izračunavanje rezultata zahtijeva da postoje redovni i pouzdani podaci o domaćinstvima i kapacitet da se ovi podaci analiziraju na odgovarajući način. Javno dostupna formula za izračunavanje rezultata doprinosi transparentnosti, ali otvara mogućnost da se radi kvalifikovanja manipulira bilo kojima od obuhvaćenih karakteristika. S druge strane, ovi kriterijumi se mogu smatrati proizvoljnim i netransparentnim ako se formula ne obznani. U svakom slučaju, način izračunavanja rezultata može biti nerazumljiv za širu javnost.

I napokon, **hibridni prihodovno-imovinski cenzus** je kombinacija elemenata prethodne dvije metode ili kombinacija kategoričkih filtera sa imovinskim ili indirektnim imovinskim cenzusom. U prvom slučaju, projicirani prihod datog podnosioca molbe predstavlja zbir zvaničnih prihoda koje je lako provjeriti, npr. plata ili transfera socijalne pomoći, i prihoda koje je teško provjeriti, iz rada u neformalnom sektoru ili eksploatacije proizvodnih fizičkih dobara koja se procjenjuju na osnovu imovinskog cenzusa Ocjenjuje se da je neki podnosilac molbe kvalifikovan ako je predviđeni prihod ispod određenog praga, ili, ako taj kriterijum važi, ako dati podnosilac molbe pripada izabranoj geografskoj ili demografskoj grupi. U najboljem slučaju, ova kombinacija omogućava veoma preciznu procjenu socijalnog položaja - čak i kod visokog nivoa neformalnosti u ekonomiji, pošto omogućava da se sve dostupne informacije optimalno iskoriste. Nedostatak je što ona traži visok nivo administrativnih kapaciteta.

U Tabeli 1 prikazan je pregled mehanizama ciljanja koji se koriste u odabranim zemljama u regionu ECA. Štaviše, pojedine konkretne karakteristike mreža socijalne zaštite u ovom regionu opisane su u tekstnim okvirima širom ovog pregleda literature, a detaljniji opisi odabranih zemalja dati su u dodatku.

**Tabela 1.** Pregled mehanizama ciljanja u odabranim zemljama ECA

| Zemlja | Naziv programa | Godina | Mehanizam ciljanja |
|---|---|---|---|
| **Albanija** | *Ndihme Ekonomika* | 1993. | Imovinski cenzus (prihodovni prag za kvalifikovanje zasnovan na veličini i sastavu domaćinstva i naknadi za nezaposlenost na nivou zemlje), kategorički kriteriji |
| **Armenija** | Porodična naknada za siromaštvo | 1999. | Indirektni imovinski cenzus |
| **Azerbejdžan** | Ciljana socijalna pomoć | 2006. | Imovinski cenzus (razmatran je indirektni imovinski cenzus, ali nedostajali su pouzdani podaci za |

| | | | |
|---|---|---|---|
| | | | simulacije, vidi Svjetska banka (2009b)) |
| **Bugarska** | Garantovani minimalni prihod | 1991. | Imovinski cenzus |
| **Estonija** | Naknade za izdržavanje | | Imovinski cenzus |
| **Gruzija** | Ciljana socijalna pomoć | 2006. | Indirektni imovinski cenzus |
| **Kazahstan** | Ciljana socijalna pomoć | 2002. | Imovinski cenzus |
| **Kazahstan** | Uslovni novčani transfer | 2009. | Indirektni imovinski cenzus |
| **Kirgistan** | Jedinstvena mjesečna naknada | 1995. | Imovinski cenzus, kategorički kriteriji, filteri |
| **Litvanija** | Socijalna naknada | 1990. | Imovinski cenzus, vrijednost imovine domaćinstva (HMT?) |
| **Rumunija** | Program garantovanog minimalnog prihoda | 2002. | Verifikovani prihodovni cenzus, samo-ciljanje |
| **Ruska Federacija** | Dječiji dodatak | 2001. | Imovinski cenzus (do 2001. kategorički za svu djecu) |
| **Tadžikistan** | Naknada socijalne pomoći | 2011. | Indirektni imovinski cenzus da se poboljšaju rezultati ciljanja, rađen pilot u dvije oblasti 2011. |
| **Uzbekistan** | Porodična naknada | 1994. | Ciljanje u zajednici |

### *1.3 Mjerenje učinka*

Ocjene učinka ciljanja ključne su da bi omogućile vladama da dotjeraju svoje mehanizme ciljanja i da pokažu transparentnost i jaku želju da obrazlože namjenu javnih resursa. Kod mjerenja učinka ciljanja, fokus je na pokazateljima ishoda koji obuhvataju rezultat na nivou korisnika (Gassman, 2010. str. 7), npr. pristup socijalnoj zaštiti (obuhvat), preciznost ciljanja ili nivo i adekvatnost socijalnih davanja. Ukupni učinak mreža socijalne zaštite, koji se analizira putem ovih indikatora, znatno se razlikuje po zemljama ECA. Štaviše, sistemi socijalne zaštite razlikuje se po administrativnim ulazima i svojim efektima na smanjenje siromaštva.

**Tekstni okvir 3.** Horizontalna i vertikalna efikasnost

Ciljanje ni u kom smislu nije savršena naučna disciplina, i do grešaka može doći i u fazi izrade i u fazi implementacije sistema. Učinak mreža socijalne zaštite može se mjeriti po različitim dimenzijama (Gassmann, 2010):

**Horizontalna efikasnost** ocjenjuje horizontalnu distribuciju (**obuhvat)** naknada i usluga po raznim kategorijama stanovništva (rodna distribucija, formalno i neformalno tržište rada, starosna distribucija, distribucija po nivou prihoda itd.). Ona se odnosi na djelotvornost sistema u dosezanju do najsiromašnijih. Nedovoljan obuhvat (**greška isključenja**, v. Tabelu 2) ciljne grupe smanjuje horizontalnu efikasnost programa (pošto je greška isključenja suprotna pokazatelju obuhvata: greška isključenja = 100 procenata - obuhvat).

**Vertikalna efikasnost** analizira vertikalnu raspodjelu naknada i usluga (**preciznost ciljanja**) i odnosi se na efikasnost sistema u dosezanju do najsiromašnijih i zatvaranju jaza siromaštva. Vertikalna efikasnost se smanjuje ako su nesiromašni među korisnicima mreža socijalne zaštite, tj. ako se povećava **greška uključenja**. Greška uključenja je suprotna pokazatelju preciznosti ciljanja: greška uključenja = 100 procenata - preciznost ciljanja). Ona se može mjeriti brojem korisnika, ali i visinom dodijeljenih naknada.

**Tabela 2.** Matrica učinkovitosti

| | Ciljna grupa | Ne-ciljna grupa |
|---|---|---|
| Domaćinstvo dobija transfer | Uspjeh | Greška uključenja |
| Domaćinstvo ne dobija transfer | Greška isključenja | Uspjeh |

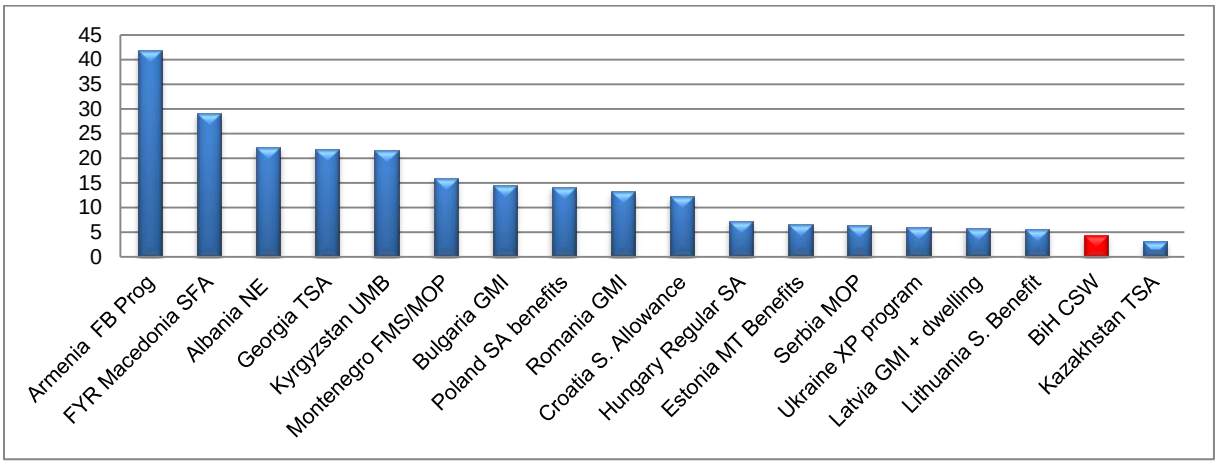
Obuhvat najsiromašnije kvintile Programima socijalne pomoći u krajnjoj nuždi (Last Resort Social Assistance Programs - LRSA)[4] je generalno nizak i u većini zemalja ECA ne prelazi 30 procenata (v. grafikon 2).[5] Razlike među zemljama su znatne. U osam od 19 zemalja, naime u Kazahstanu, BiH, Litvaniji, Letoniji, Ukrajini, Srbiji, Estoniji i Mađarskoj, manje od 10 procenata pripadnika najsiromašnije kvintile su obuhvaćeni programima za krajnju nuždu,

[4] Ovi programi uglavnom ciljaju domaćinstva s najvećim potrebama u datoj zemlji. Metode ciljanja se razlikuju od metoda prihodovnog preko imovinskog do hibridnog prihodovno-imovinskog cenzusa.

[5] Obratite pažnju da se, u svrhu dosljednih poređenja među zemljama, u svakoj zemlji najsiromašnija kvintila stanovništva smatra ciljnom grupom. Ocjene efekata na nacionalnom nivou mogu odstupati od ovog pristupa i definisati ciljnu grupu odgovarajućim zakonima svake zemlje.

dok u Armeniji ciljani programi dosežu oko 40 procenata domaćinstava u najsiromašnijoj kvintili. Visok nivo potrošnje ne znači nužno veći obuhvat siromašnih, što potvrđuje i primjer Bosne i Hercegovine. Iako se izdvajaju visinom potrošnje za mreže socijalne zaštite (oko 4 procenta BDP ide na socijalnu pomoć), naknade LRSA stižu do svega oko 4 procenta pripadnika najsiromašnije kvintile, pošto su kriterijumi kvalifikovanja za druge transfere socijalne pomoći često više zasnovani na pravima nego na potrebama.

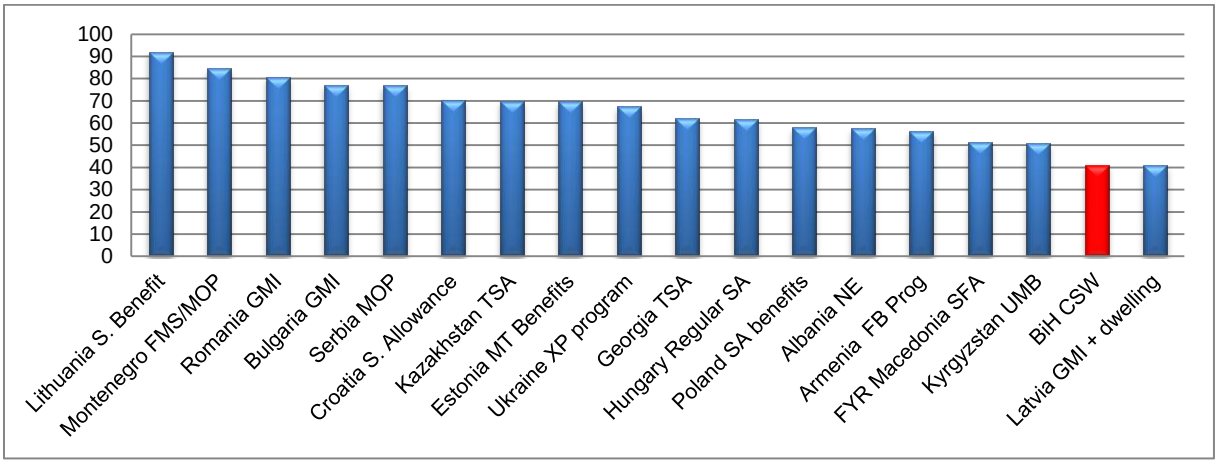
**Grafikon 8.** LRSA: Obuhvat najsiromašnije kvintile (u %)




*Izvor:* Svjetska banka, Social Expenditure Database 2011.

Štaviše, preciznost ciljanja se takođe značajno razlikuje od jedne do druge zemlje u regionu ECA (v. grafikon 3). U Bosni i Hercegovini, najsiromašnijih 20 procenata domaćinstava prima oko 40 procenata naknada koje dodjeljuju centri za socijalni rad, dok je ciljanje posebno precizno u Litvaniji, Crnoj Gori, Rumuniji, Bugarskoj i Srbiji. U ovim zemljama, negdje od 80 do 90 procenata naknada se usmjerava najsiromašnijoj kvintili. U većini zemalja ciljna grupa dobija između 50 i 70 procenata sredstava budžetiranih za ove namjene.

**Grafikon 9.** LRSA: Preciznost ciljanja (procenat ukupnih naknada koji prima najsiromašnija kvintila (u %)

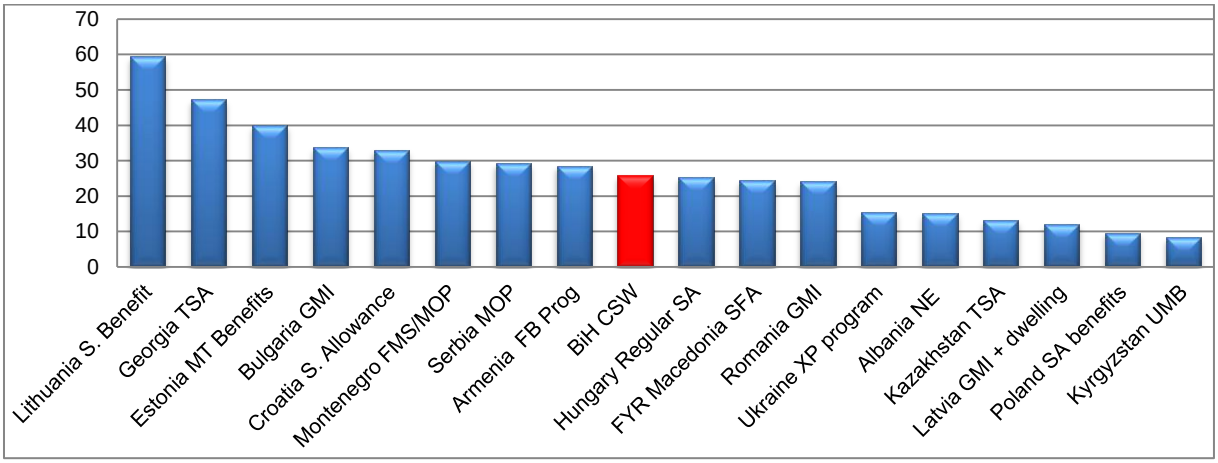



*Izvor:* Svjetska banka, Social Expenditure Database 2011.

Kao mjera nivoa i adekvatnosti socijalnih naknada, transfer koji primaju sva domaćinstva u najsiromašnijoj kvintili izražava se kao udio u potrošnji svih korisničkih domaćinstava u toj kvintili nakon transfera (v. grafikon 4). Najizdašniji transferi u regionu ECA su socijalna

naknada u Litvaniji, ciljana socijalna pomoć u Gruziji i prihodovne naknade u Estoniji. Nasuprot ovome, jedinstvena mjesečna naknada (Unified Monthly Benefit - UMB) u Kirgiskoj Republici i ciljana socijalna pomoć (Targeted Social Assistance - TSA) u Poljskoj predstavljaju tek oko jednu desetinu potrošnje korisničkog domaćinstva nakon transfera, što znači da tek u vrlo ograničenoj mjeri doprinose dobrobiti datog domaćinstva.

**Grafikon 10.** LRSA: Naknade kao procenat potrošnje nakon transfera, po korisničkim domaćinstvima, za najsiromašniju kvintilu




*Izvor:* Svjetska banka, Social Expenditure Database 2011.

**Tekstni okvir 4.** Garantovani minimalni prihod u odnosu na liniju siromaštva

Stepen izdašnosti je osnovno pitanje u dizajniranju pomoći i zavisi od cilja programa i njegovog ukupnog budžeta. U mnogim zemljama regiona ECA postoje programi garantovanih minimalnih prihoda, u kojima su naknade tako dizajnirane da popune jaz između prihoda date porodice i minimalnog prihoda, tj. ovaj utvrđeni minimalni prihod služi i kao kvalifikacioni prag i kao maksimalni nivo iznosa naknade. Idealno, ovaj standard se povezuje s minimalnim nivoom preživljavanja koji se ili definiše normativno ili utvrđuje empirijski na osnovu stvarnih potrošačkih navika stanovništva. Međutim, faktor koji određuje ovaj iznos u praksi je često fiskalni prostor. Štaviše, redovnim prilagođavanjem naknada treba osigurati da naknade s vremenom ne budu umanjene zbog inflacije ili da ne zaostaju za trendovima plata. Međutim, u mnogim okolnostima ovakva prilagođavanja dešavaju se neredovno, na *ad hoc* osnovi i na temelju raspoloživosti finansijskih sredstava (Grosh i drugi, 2008; Svjetska banka, 2011a).

Na primjer, Vlada Kirgiske Republike je 1998. uvela garantovani minimalni prihod (GMI) a prilagođavanja se vrše na *ad hoc* osnovi. Raspoloživi budžet i očekivani broj korisnika određuju nivo GMI i visinu naknade. 1998. godine, naknada je iznosila polovinu iznosa linije krajnjeg siromaštva, koja predstavlja monetarnu vrijednost prehrambene korpe koja daje 2.100 kcal. I mada je bilo zamišljeno da se GMI stalno približava liniji krajnjeg siromaštva, od tada se pojavio suprotan trend. Deset godina kasnije, GMI je tek jedna petina iznosa linije krajnjeg siromaštva (Gassmann, 2011b, str. 5).

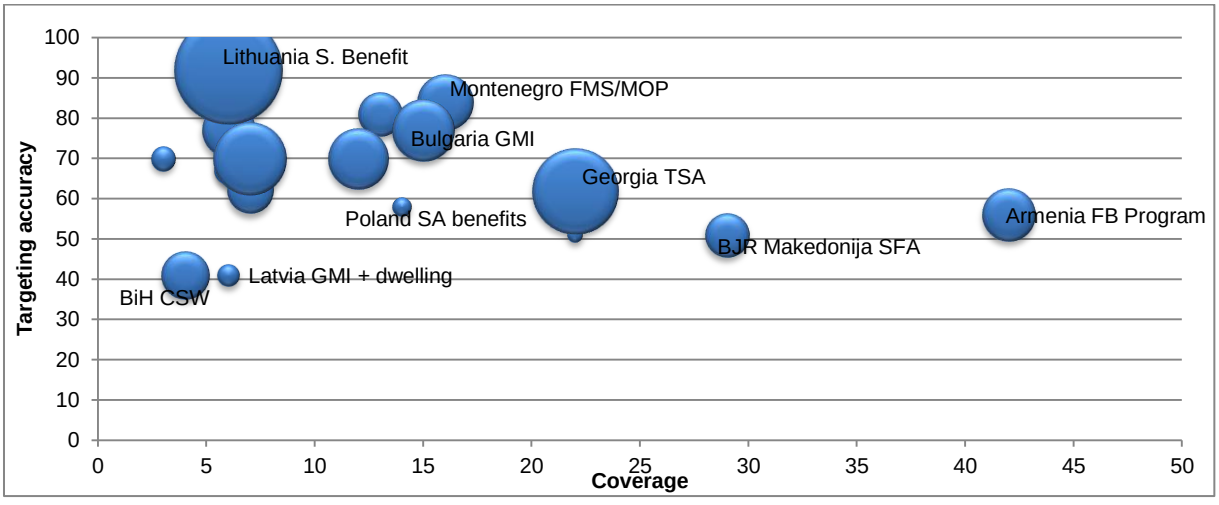
**Tekstni okvir 5.** Program garantovanog minimalnog prihoda u Bugarskoj[6]

U Bugarskoj postoje dva osnovna modela budžetskih programa mreža socijalne zaštite u Bugarskoj: model garantovanog minimalnog prihoda (GMI) i model naknade za grijanje (Heating Allowance - HA), koji pokrivaju ugrožena domaćinstva s niskim prihodima. I GMI i HA su programi zasnovani na provjeri prihoda (i imovine). Cilj je da se osigura zaštita najsiromašnijih i najugroženijih pojedinaca i njihovih domaćinstava u podnošenju šokova po prihode i siromaštva (Svjetska banka, 2009b).

Program GMI uveden je 1991. da se osigura novčana naknada za pojedince i domaćinstva koja su ispod određenog nivoa prihoda. Ova naknada teži da popuni jaz između prihoda domaćinstva i praga koji utvrdi Vijeće ministara (obično jednom godišnje) kao cijenu korpe osnovnih prehrambenih proizvoda. Kriteriji kvalifikovanja zasnivaju se na prihodima korisnika i njihovih domaćinstava, imovini, veličini porodica, zdravstvenom i obrazovnom statusu, starosti i drugim uočenim okolnostima. Stvarni mjesečna GMI naknada jednaka je razlici između diferenciranog minimalnog prihoda ili zbira diferenciranih minimalnih prihoda i stvarnih prihoda korisnika u mjesecu koji je prethodio podnošenju molbe za ovu naknadu. GMI naknada se odobrava nakon što kandidat popuni detaljan upitnik o socijalnom statusu a socijalni radnik provjeri date informacije.

Na grafikonu br. 11 sumiran je učinak prihodovnih mreža socijalne zaštite u zemljama regiona ECA sa aspekta obuhvata, preciznosti ciljanja i transfera najsiromašnijoj kvintili. Grafikon posebno ilustruje kompromis između greške uključenja i greške isključenja (vidjeti Okvir 6), pošto neke od zemalja sa najboljim učinkom u pogledu preciznosti ciljanja imaju slab rezultat kad je u pitanju obuhvat. Iako u Litvaniji više od 90 procenata ukupnih naknada dobijal najsiromašnija kvintila, ovaj program obuhvata svega šest procenata ciljne grupe. U Armeniji, obuhvat ciljne grupe je izuzetno visok (42 procenta) ali isto važi i za prelijevanje nesiromašnim domaćinstvima, pošto se tek nešto više od polovine naknada usmjerava najsiromašnijoj kvintili. Program GMI u Letoniji je po bilo kom indikatoru učinka među najgorima.

**Grafikon 11. LRSA:** Preciznost ciljanja, obuhvat i adekvatnost za najsiromašniju kvintilu




*Napomena:* Veličina kruga odražava veličinu i prema tome adekvatnost transfera.
*Izvor:* Svjetska banka, Social Expenditure Database 2011.

[6] Molimo pogledajte Dodatak za više pojedinosti.

**Tekstni okvir 6.** Kompromisi između greške uključenja i greške isključenja

Greška uključenja i greška isključenja, i na njima zasnovane komparativne procjene, zahtijevaju kritičko tumačenje (v. Coady & Skoufias, 2001). Nije bitno samo *koliko* je isključenih, već i *ko* je isključen. Greška ciljanja je teža ako krajnje siromašno domaćinstvo nije obuhvaćeno, u poređenju sa domaćinstvom čiji su prihod ili potrošnje negdje oko linije siromaštva. Štaviše, greške uključenja i isključenja ne otkrivaju ništa o adekvatnosti transfera.

Cilj maksimizacije unapređenja dobrobiti za siromašne u okviru budžetskih ograničenja zahtijeva značajne kompromise između greške uključenja i greške isključenja. Restriktivniji kriteriji kvalifikovanja mogu odvratiti od podnošenja molbe upravo one kojima su najpotrebniji. Usto, greške uključenja i isključenja su osjetljive na obuhvat u datom programu - mali program će prije patiti zbog velike greške isključenja i male greške uključenja, i obratno ako dati program obuhvata širi segment stanovništva. Ovdje su bitni i politički momenti. Dok će Ministarstvo finansija težiti da smanji grešku uključenja da bi minimiziralo odliv finansijskih sredstva domaćinstvima koja nisu u stanju potrebe, Ministarstvo za socijalna pitanja će prije nastojati da ograniči grešku isključenja siromašnih domaćinstava. S obzirom na ekonomske krize i tekuće procese budžetske konsolidacije u mnogim zemljama, fokus je često na greškama uključenja.

**Tekstni okvir 7.** FGT indikatori siromaštva i njihov uticaj na smanjenje siromaštva

FGT (Foster, Greer i Thorbecke) indikatori siromaštva obuhvataju indeks broja siromašnih, indeks jaza siromaštva, i indeks kvadrata jaza siromaštva. **Indeks broja siromašnih** otkriva koji dio stanovništva se smatra siromašnim. **Indeks jaza siromaštva** mjeri koliko su daleko siromašni, u prosjeku, ispod linije siromaštva, i on se izražava u procentima linije siromaštva. I konačno, **indeks kvadrata jaza siromaštva** je ponderisani zbir linija siromaštva, tako da opažanja imaju veći ponder što su dublje ispod linije siromaštva (Haughton & Khandker, 2009, str. 67-73).

Tip indikatora siromaštva koji se koristi za poređenja položaja domaćinstava prije i nakon transfera je bitan. Transfer namijenjen pojedincima neposredno ispod linije siromaštva može biti vrlo djelotvoran u smanjenju broja siromašnih, ali ne i jaza siromaštva. Nasuprot tome, isti iznos socijalnih transfera, ali usmjeren ka krajnje siromašnim, može dovesti do praktično nikakve promjene u broju siromašnih, ali može značajno doprinijeti sužavanju jaza siromaštva (Gassmann, 2011b, pp. 16–17).

U Kirgiskoj Republici, efekat UMB na smanjenje siromaštva ostaje ograničen uprkos dobroj preciznosti ciljanja i mogao bi se unaprijediti proširenjem obuhvata i povećanjem iznosa naknade (Svjetska banka, 2009c, str. 14). I na kraju, u Bosni i Hercegovini, procjenjuje se da socijalne naknade iz budžeta smanjuju broj siromašnih za pukih 1,2 procenata (Svjetska banka, 2009c, str. 14).

Mreže socijalne zaštite se još razlikuju i po razmjerama administrativnih inputa. Poređenje troškova po zemljama traži oprez, pošto veći udio administrativnih troškova u ukupnim programskim rashodima ne znači nužno da ciljanje nije vrijedno truda radi unapređenja sveukupne efikasnosti datog programa. Istovremeno, upadljivo niski administrativni troškovi ne ukazuju automatski na efikasno djelovanje programa, već mogu ukazati i na nedovoljnost

u administraciji. Na primjer, veoma ograničeni administrativni budžet za dječji dodatak u Rusiji imao je za posljedicu velike nedostatke u pogledu ciljanja, monitoringa i evaluacije (Grosh i drugi, 2008, str. 391-392).

Troškovi prihodovnih ili indirektnih imovinskih programa navedenih u Tabeli 3 su relativno niski (Grosh i drugi, 2008, str. 94). U pogledu obuhvaćenih zemalja ECA, troškovi ciljanja kao udio u ukupnim troškovima programa kreću se od 0,6 procenata za Program naknada za siromašne porodice u Armeniji do 6,3 procenata u bugarskom Programu garantovanih prihoda (GMI). Na poređenja troškova po programima i zemljama utiče još nekoliko faktora, konkretno: veličina transfera, da li se isti sistem ciljanja koristi za ocjenu kvalifikovanja za više programa, troškovi radni snage i činjenica da su troškovi obično viši u početnoj fazi datog programa (Grosh i drugi, 2008, str 93-94).

Sve u svemu, potrošnja na mreže socijalne zaštite znatno varira po zemljama u regionu ECA, kao i učinak u pogledu obuhvata, preciznosti ciljanja i nivoa naknada. Upečatljivo je da viša ukupna potrošnja na socijalnu pomoć nije nužno praćena većim obuhvatom i preciznijim usmjeravanjem resursa ka siromašnim i ugroženim segmentima stanovništva, kao što posebno pokazuje primjer Bosne i Hercegovine u poređenju sa susjednim zemljama.

**Tabela 3.** Administrativni troškovi ciljanja za odabrane prihodovne i indirektne imovinske programe, različite godine

| Zemlja, program, godina | Troškovi ciljanja kao udio u ukupnim… | | USD/ korisnik |
|---|---|---|---|
| | administrativnim troškovima | programskim troškovima | |
| Albanija: Ndihme Ekonomika, 2004. | 88 | 6,3 | 7 |
| Armenija: Program naknada za siromašne porodice, 2005. | 26 | 0,6 | 3 |
| Bugarska: Program garantovanih minimalnih prihoda (GMI), 2004. | 64 | 6,3 | 7 |
| Kirgiska Republika: Program jedinstvenih mjesečnih naknada, 2005. | 24 | 2,3 | 1 |
| Litvanija: Program socijalne naknade, 2004. | 41 | 2,7 | 8 |
| Rumunija: Program garantovanih minimalnih prihoda (GMI), 2005. | 71 | 5,5 | 25 |
| Kolumbija: Familias en Acción, 2004. | 34 | 3,6 | - |
| Meksiko: PROGRESA, 1997-2000. | 40 | 2,4 | - |

*Izvor:* Grosh i drugi. (2008, str. 94).

## 2 Indirektni imovinski cenzus

### 2.1 Malo istorije

Cilj usmjeravanja naknada programa socijalne zaštite ka onima kojima su najkritičnije potrebni zavisi od korektne ocjene socijalnog položaja pojedinca ili domaćinstva. Iako su prihodovni cenzusi teoretski najpreciziniji način ocjene socijalnog položaja, njihova stvarna preciznost zavisi od konteksta. Postoje ograničenja u korištenju prihodovnoh cenzusa u zemljama gdje su prihodi niži i koje obično karakterišu visok nivo neformalnosti u ekonomiji, velika raširenost naturalne poljoprivrede i ograničeni institucionalni i administrativni kapaciteti. I kad se prihodovni cenzus koristi, on podliježe pojednostavljenjima koja mogu ugroziti uspješnost ciljanja (v. Grosh & Baker, 1995). U tom kontekstu treba posmatrati ideju da se za utvrđivanje nivoa socijalnih potreba koriste razni zamjenski ili indirektni kriteriji.

Indirektni imovinski cenzus je prvi put sproveden u Čileu 1980. a druge latinoameričke zemlje slijedile su ovaj primjer narednih godina pošto su ciljani pristupi socijalnoj potrošnji za siromašne postali popularniji u svjetlu finansijskih organičenja i politika koje su stremile da se ograničeni resurse usmjere onima koji ne mogu zadovoljiti ni osnovne potrebe (Castañeda, 2005.). U prvoj fazi čileanskog sistema Ficha CAS (1980-87, CAS-I), socijalni radnici prikupljali su podatke o četrnaest varijabli o karakteristikama domaćinstva i njegovih članova i kvalifikovanost se određivala izračuvanjem finalnog rezultata na temelju jedne tabele o dodjeli pondera neposredno na kraju svakog intervjua. Varijable koje su uključene, kao i konkretni ponderi, određeni su na osnovu ankete koja se oslonila na analizu glavnih komponenti (faktorska analiza). U narednoj fazi programa, ovaj upitnik je produžen da se unaprijedi preciznost, a tačna formula za utvrđivanje rezultata više nije objavljivana da bi se izbjegle manipulacije (Gros & Baker, 1995.).

U Kolumbiji je 1991. godine Ustavom utvrđeno da će se socijalna potrošnja usmjeravati ljudima koji ne mogu zadovoljiti osnovne potrebe. Indirektni imovinski cenzus je isproban jer su visok stepen neformalnosti u ekonomiji i neprijavljivanje prihoda ozbiljno otežavali primjenu prihodovnog cenzusa, pošto verifikacija ne bi bila moguća. Isto tako, geografsko ciljanje nije bilo pogodan metod jer se njime dvije trećine stanovništva kvalifikovalo kao da živi u stanju potrebe. Kolumbijski SISBEN indeks je, alternativno, određivao socijalni položaj domaćinstava kroz kvalitet stambenih jedinica i posjedovanje trajnih potrošnih dobara, korištenje javnih komunalnih službi, ljudski kapital i porodičnu demografiju (Castañeda, 2005).

Pošto se u Latinskoj Americi sve više koristio, indirektni imovinski cenzus se proširio i na druge dijelove svijeta. U regionu Evrope i Centralne Azije, Armenija je devedesetih godina počela s primjenom indirektnog imovinskog cenzusa na osnovu iskustva tokom distribucije humanitarne pomoći. Pomoć se prvo, prije uvođenja indirektnog imovinskog cenzusa, dodjeljivala na osnovu prioriteta i prema kategorijalnim karakteristikama. Kada su tzv. porodične naknade zamijenile skup drugih naknada 1999. godine, prilagođena formula indirektnog imovinskog cenzusa izabrana je za ciljanje.

### 2.2 Dizajn indirektnog imovinskog cenzusa

Kalibracija indirektnog imovinskog cenzusa zahtijeva opsežan skup dobro obrazloženih metodoloških odluka. Nakon što se predstave razni načini određivanja formule za indirektni imovinski cenzus, razmatraju se odluke kao što su izbor odgovarajućih varijabli, kao i neki metodološki problemi i načini njihovog prevazilaženja. Pošto implikacije čaki i naizgled sitnih

odluka mogu biti znatne, kreatori politika treba da budu svjesni posljedica. (AusAID, 2011, str. 19).

### *a. Metodološke odluke*

Osnovna ideja indirektnog imovinskog cenzusa je da se prihod iz raznih razloga ne može koristiti kao indikator socijalnog položaja, npr. zbog niskog nivoa formalnosti na tržištu rada. Umjesto toga, oslonac se nalazi u skupini karakteristika domaćinstva koje se lako uočavaju i koje su u korelaciji sa siromaštvom,[7] tzv. zamjenske (proxy) karakteristike. Problem je da se utvrdi skup zamjenskih karakteristika koji daje najbolje procjene socijalnog položaja domaćinstava. Svakoj zamjenskoj karakteristici se, na osnovu njenog relativnog uticaja na socijalni položaj, pripisuje određeni ponder. Pored izbora najpogodnijih karakteristika domaćinstava i dodjeljivanja pondera svakoj od njih, za utvrđivanje da li je neki kandidat kvalifikovan za primanje pomoći potrebno je utvrditi graničnu vrijednost.

#### *Izračunavanje rezultata po indikatorima*

Generalno, postoje dva načina da se rezultati po indikatorima empirijski izvedu, naime regresivna analiza i metoda glavnih komponenti. Obje metode oslanjaju se na podatke iz anketa sa domaćinstvima. Na izbor bilo koje od ove dvije metode dijelom utiče činjenica da li anketa sa domaćinstivima oubhvata ikakve procjene potrošnje ili prihoda.[8] Prvo, **regresiona analiza** koristi statističke modele regresije da se procijeni mjera u kojoj je data varijabla po potrošnji (ili prihodu) povezana sa siromaštvom, kao zavisnom varijablom. Nakon toga, procijenjeni koeficijenti regresije koriste se kao ponderi u formuli PMT, pošto oni odražavaju relativni uticaj date karakteristike domaćinstva na siromaštvo, ne mijenjajući ništa drugo. Bitno je prepoznati da se na osnovu ovakve statističke analize ne mogu utvrditi bilo kakvi kauzalni odnosi, već se samo može procijeniti stepen povezanosti neke varijable sa siromaštvom.

Drugo, posebno ako u anketi sa domaćinstvima nema procjena prihoda ili potrošnje, može se primijeniti **metoda glavnih komponenti**. I opet je krajnji cilj odrediti skup indikatora koji najpreciznije predviđaju socijalni položaj domaćinstava. Konkretnije, metoda glavnih komponenti utvrđuje linearnu kombinaciju karakteristika domaćinstva koja maksimizuje uočene varijacije među porodicama, ili geografskim područjima. Te se karakteristike zatim uključuju u kompozitni indeks PMT. Odluke o ponderima se ili izvode iz analize glavnih komponente i/ili se zasnivaju na kvalitativnim informacijama o relativnoj važnosti svake od datih karakteristika. Pošto ovo zahtijeva dodatne debate, za razradu indeksa PMT može trebati više vremena nego za primjenu pondera izvedenih iz regresione analize. Primjeri formula PMT zasnovanih na analizi glavni komponenti uključuju čileanski Ficha CAS,

[7] Potrebno je krenuti od jasne definicije siromaštva i donijeti odluku o indikatoru koji će se koristiti za mjerenje siromaštva. Nasuprot standardnoj ekonomiji životnog standarda, koja se usredsređuje na korist kao mjerilo socijalnog statusa i koja mjeri nedostatak novca, multidimenzionalni pristup širi domen analiza siromaštva jer naglašava da oskudica može imati više dimenzija, npr. obrazovanje, zdravstvo ili stambeni uslovi. Temeljni koncept siromaštva, njegova operacionalizacija i mjerenje nose važne implikacije za ciljanje i politike (Ruggeri Laderchi, Saith & Stewart, 2003). Ovaj pregled se uglavnom usredsređuje na novčano siromaštvo kao najšire korišteno mjerilo siromaštva.

[8] U principu, potrošnja je bolja od prihoda kao indikator socijalnog položaja iz više razloga. Prvo, respondenti u anketi su skloniji da prijave niže prihode nego potrošnju, npr. radi izbjegavanja poreza. Drugo, ako je velik dio prihoda domaćinstva u naturi, potrošnju je lakše porediti sa drugim domaćinstvima. I konačno, potrošnja je manje podložna sezonskim fluktuacijama (Grosh & Baker, 1995, str. 10).

kostarikanski SIPO, meksički *Oportunidades* i kolumbijski SISBEN. U regionu ECA, ponderi korišteni u armenijskoj formuli PMT zasnovani su na mišljenjima eksperata, anketi o mišljenjima socijalnih radnika i političkim procjenama (Harutyunyan, 2005.).[9]

**Tabela 4.** Dvije metode za definisanje varijable i pondera za indirektni imovinski cenzus (PMT)

| | **Regresiona metoda (prediktori)** | **Metoda glavnih komponenti** |
|---|---|---|
| Metoda | Koristi statističke regresione modele sa podacima iz anketa sa domaćinstvima da odredi koje varijable "predviđaju" siromaštvo po potrošnji (ili prihodu). Regresioni koeficijenti se zatim koriste kao ponderi u kompozitnom PMT indeksu. | Identifikovati linearne kombinacije varijabli mjerenih u anketama s domaćinstvima da se maksimizuje uočena varijacija između porodica i geografskih područja. Te varijable se zatim uključuju u kompozitni PMT indeks. Generalno, ovaj pristup se kombinuje sa stručno-tehničkom analizom da se odrede ponderi indeksa. |
| Bolje radi kad | ... su dostupni pouzdani podaci iz anketa sa domaćinstvima o potrošnji (ili prihodu) (da posluže kao zavisna varijabla u regresijama). | ... pouzdane procjene o potrošnji iz anketa sa domaćinstvima nisu dostupne (na regresionu metodu). Ova metoda je korisna da se smanji broj varijabli za uključenje u upitnik za PMT. |
| Prednosti | Transparentno, objektivno izračunavanje pondera, relativno jednostavno i brzo dizajniranje kompozitnih indeksa (oko 2 mjeseca rada) | Omogućava stručnjacima (i društvu) da ugrade kvalitativne informacije o relativnoj važnosti varijabli (radi određivanja pondera); jednom kada budu određeni, ovi indeksi su transparentni; ali dizajniranje indeksa traje duže nego kod regresione metode (zbog rasprava i diskusija i ponderima). |

*Izvor:* Castañeda i Lindert (2005, str. 26).

*Izbor varijabli*

Varijable koje se često koriste u formulama za rangiranje odnose se na lokaciju, kvalitet stambenih jedinica (npr. materijal za izradu krova, zidova i poda, uklanjanje čvrstog otpada i odvod otpadnih voda), posjedovanje trajnih potrošnih dobara (npr. televizora, hladnjaka, mašina za pranje veša), obrazovanje (npr. nepismenost, redovnost pohađanja škole, broj godina obrazovanja), zanimanje i prihodi. U druge mogućnosti spadaju indikatori sastava domaćinstva, kao što je broj djece ili opšta veličina domaćinstva, zdravstveni status ili invalidnost, ili drugi transferi socijalne zaštite. U regresionoj analizi, "stepwise" (korak po korak) funkcija se može upotrijebiti za eliminaciju varijabli koje nisu statistički značajne i koje ne doprinose povećanju objašnjene varijacije u socijalnom položaju domaćinstava. Često se konkretna definicija varijabli obuhvaćenih ovim modelom utvrđuje metodom pokušaja i pogreške. Na promjer, prisustvo djece u datom domaćinstvu može se prikazati brojem djece ili kategorijskim varijablama koje omogućuju razlikovanje domaćinstva sa različitim brojem

[9] Molimo pogledajte detaljniji opis date zemlje u Dodatku.

djece. Varijable uključene u model mogu se razlikovati i za urbana i ruralna područja, što traži kalibraciju posebnih modela za svaku od lokacija. U konačni model uključuju se samo varijable čija je korelacija sa socijalnim položajem najjača (Castañeda i Lindert, 2005; Grosh i Baker, 1995.).

**Tekstni okvir 8.** Indirektni imovinski cenzus u Gruziji

2006. godine, Gruzija je uvela novi sistem ciljane socijalne pomoći (Targeted Social Assistance - TSA), u kome se kvalifikovanost utvrđuje indirektnim imovinskim cenzusom. Indikatori i njihovi skorovi se izvode regresionom analizom. Ispočetka, dati skup indikatora obuhvatao je informacije o članovima domaćinstva, poljoprivrednoj aktivnosti, prihodima, uslovima života, vlasništvu nad trajnim dobrima, lokaciji, godišnjim rashodima na trajna potrošna dobra i ocjenu voditelja intervjua. Odnedavno, ovaj model je rekalibrisan, pri čemu su se promijenili ponderi za neke indikatore, neki indikatori su eliminisani a oni indikatori koje je bilo teško mjeriti (npr. rashodi) su svedeni na minimum. S druge strane, dodati su neki novi indikatori.

Izvadak iz formule PMT:

$$C = \exp(L_0 + L_1 \ln(1 + \sum_{j=1}^{6} \mathrm{k}_{1\mathrm{j}} \mathrm{Y}_{1\mathrm{j}} + L_2 \ln(1 + \sum_{j=1}^{6} \mathrm{k}_{2\mathrm{j}} \mathrm{Y}_{2\mathrm{j}}) +$$

$$L_3 \ln(1 + \sum_{j=1}^{19} \mathrm{k}_{3\mathrm{j}} \mathrm{Y}_{3,\mathrm{j}}) + L_4 (k_{40} \ln(1 + \sum_{\mathrm{j}=1}^{17} \mathrm{Y}_{4,\mathrm{j}}) + \sum_{j=1}^{5} k_{4j} sign(Y_{4,j+17})) +$$

$$L_5 (\sum_{\mathrm{j}=1}^{12} \mathrm{k}_{5\mathrm{j}} \mathrm{sign}(\mathrm{y}_{5,\mathrm{j}}) + \mathrm{k}_{5,13} \ln(1 + \mathrm{y}_{5,13}) + \mathrm{k}_{5,14} \ln(1 + \mathrm{y}_{5,14})) + \sum_{j=1}^{4} L_{6j} Y_{6j} +$$

$$\sum_{j=1}^{3} L_{7j} y_{7j} + \mathrm{L}_{81} \mathrm{Y}_{81} + \mathrm{L}_{82} \sum_{j=1}^{6} k_{82j} Y_{82j} + \sum_{\mathrm{j}=1}^{9} \mathrm{L}_{9j} \cdot \mathrm{Y}_{9\mathrm{j}} + L_{10} (\sum_{j=1}^{5} k_{10,1j} Y_{10,1j} +$$

$$\sum_{j=1}^{5} k_{10,2j} Y_{10,2j} + \sum_{j=1}^{4} k_{10,3j} Y_{10,3j} + \sum_{j=1}^{5} k_{10,4j} Y_{10,4j} + \sum_{j=1}^{5} k_{10,5j} Y_{10,5j}))$$

U zavisnosti od ukupnih rezultata domaćinstva, ono se kvalifikuje za razne vrste naknada. Domaćinstva čiji je skor ispod 57.000 kvalifikuju se za novčane transfere, zdravstveno osiguranje i subvencije za električnu energiju. S druge strane, domaćinstva čiji je skor između 70.000 i 200.000 kvalifikuju se samo za subvencije za električnu energiju.

Uvođenje PMT znatno je poboljšalo efikasnost ciljanja kod gruzijskog programa TSA:

| | Decile potrošnje | | | | | | | | | |
|---|---|---|---|---|---|---|---|---|---|---|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| 2004. | 5,0% | 10,6% | 10,0% | 10,6% | 10,6% | 10,0% | 10,0% | 9,4% | 10,6% | 13,1% |
| 2005. | 4,6% | 10,8% | 12,3% | 10,0% | 10,4% | 10,8% | 11,2% | 8,8% | 8,8% | 12,3% |
| 2006. | 1,.1% | 12,8% | 11,3% | 10,4% | 9,5% | 9,2% | 8,6% | 8,6% | 7,6% | 8,9% |
| 2007. | 13,0% | 14,0% | 11,3% | 10,6% | 10,4% | 9,2% | 9,2% | 7,7% | 7,2% | 7,5% |

*Izvor:* Implementacija sistema TSA u Gruziji, Tbilisi 2012.

Osim što su u visokoj korelaciji sa statusom siromaštva datog domaćinstva, izabrane varijable moraju zadovoljiti još čitav skup dodatnih uslova. Prvo, treba da budu **praktične** u smislu da ih je lako uočavati i verifikovati, ali da nije vjerovatno da će se njima manipulisati. Ahmed i Bouis (2002.) su pokazali na koji način tehnički i administrativni aspekti utiču na izbor indikatora. U procesu kalibracije i testiranja kompozitnog indeksa PMT za ciljanje subvencija za hranu u Egiptu, eliminisane su varijable koje su tražile da socijalni radnici vrše proračune (npr. stepen zavisnosti, kvadrat veličine domaćinstva) da terensko osoblje donosi prosudbe (rod nosioca domaćinstva, urbana nasuprot ruralnoj lokaciji datog domaćinstva), detaljnija istraživanja (npr. varijable imovine), iako su sve one bile statistički značajne u okviru OLS regresionog modela. Štaviše, konačno je odlučeno da se eliminišu vještačke varijable za jedinice lokalne uprave, pošto bi ovo dovelo do razlika u iznosu naknada po osobi između različitih administrativnih jedinica i moglo bi u najgorem slučaju dovesti i do političkog nezadovoljstva.

Drugo, **optimalni broj varijabli** treba pažljivo razmotriti. Uspostavljanje bogatijeg skupa karakteristika domaćinstva često povećava objašnjenu varijaciju u socijalnom položaju domaćinstava i time poboljšava preciznost ciljanja. Međutim, ova poboljšanja treba odmjeriti nasuprot višim troškovima verifikacije, kao i većoj mogućnosti pogrešnog prikaza (Grosh i Baker, 1995, str. 16). Grosh i Baker kao primjer za ove aspekte procjenjuju četiri sve bogatija modela koja objašnjavaju sve više i više varijacija u socijalnom položaju domaćinstava, koristeći podatke sa Jamajke. Četvrti model je jedini koji koristi vještačke varijable za posjedovanje trajnih potrošačkih dobara. U isto vrijeme, prilagođeni koeficijent determinacije povećava se na 0,41 u poređenju sa već dosegnutih 0,36 u skromnijem trećem modelu. Prema tome, prednosti neznatno veće preciznosti ciljanja moraju se uporediti sa dodatnim troškovima obrade informacija.

Treće, potrebno je odlučiti u kojoj mjeri formula PMT treba da odražava **hronično ili prolazno siromaštvo**. Implicitna karakteristika dizajna formula za izračunavanje PMT je da se mnoge varijable odnose na prilično statične karakteristike datog domaćinstva, kao što su varijable ljudskog kapitala ili posjedovanje određene imovine. Rezultat je da je indirektni imovinski cenzus podesniji za tretiranje hroničnog nego prolaznog siromašva (Castañeda & Lindert, 2005, str. 17). Postavlja se konkretno pitanje da li je ovdje prihod uključen kao nezavisna varijabla. Njegovo uključenje doprinosi da se uzme u obzir i prolazno siromaštvo. U isto vrijeme, ono stvara potrebu za redovnijim ažuriranjem i administrativno je zahtjevnije verifikovati pribavljene informacije, koje su mogle biti podvrgnute manipulisanju radi dobijanja socijalnih naknada. U ovom pogledu, postoje primjetne razlike u međunarodnoj praksi.

*Preciziranje modela*

Pored odabira najpodesnijih karakteristika domaćinstava, regresioni model se može procjenjivati odvojeno za različite podgrupe stanovništva, čime se omogućava da i varijable uključene u svaki od modela, a i koeficijenti, tj. ponderi, variraju. Obrazloženje je da postoje velike razlike između pojedinih potkategorija stanovništva, tako da za obuhvat takvih "varijacija u oblicima" siromaštva treba razviti specifične modele (Castañeda i Lindert, 2005, str. 25). Na primjer, odvod vode i otpadnih voda je često manji problem u urbanim centrima i relativno je slab indikator siromaštva u urbanizovanom kontekstu, dok jednako dobrostojeća domaćinstva u ruralnim oblastima u ovom pogledu možda nisu dobro povezana. U isto vrijeme, potrebno je uravnotežiti povećanu administrativnu složenost naspram ušteda uzrokovanih većom preciznošću ciljanja (Grosh i Baker, 1995, str. 19-21).

Slična argumentacija objašnjava zašto je potrebno eksplicitno se odlučiti po kom segmentu stanovništva se utvrđuju ponderi. Pošto su mreže socijalne zaštite obično usmjerene ka najsiromašnijim i najugroženijim kategorijama stanovništva, u praksi indirektni imovinski cenzus će se vjerovatno primjenjivati na niže decile u distribuciji socijalnog stanja. Shodno tome, možda je prikladnije da se za kalibraciju indirektnog imovinskog cenzusa uzme u obzir samo siromašnija polovina stanovništva. Grosh i Baker pokazuju da ovakav oblik dotjerivanja može dramatično uvećati preciznost ciljanja (1995, str. 21-23).

**Tekstni okvir 9.** Pilot za indirektni imovinski cenzus u Tadžikistanu

Sistem socijalne pomoći u Tadžikistanu je malen. Obuhvata dva tipa naknada: naknade za električnu energiju i plin i novčanu naknadu za djecu iz siromašnih porodica. Kvalifikovane porodice se identifikuju kombinacijom ciljanja preko zajednice i imovinskog cenzusa. 2009. godine, ukupni budžet utrošen na socijalnu pomoć (uključujući i socijalne penzije) bio je 22 miliona $, što predstavlja 0,45 procenata BDP zemlje (Svjetska banka, 2011b). Obuhvat naknadama socijalne pomoći je izuzetno ograničen a nivo naknada je nizak. Naknade prima samo 19 procenata pripadnika najsiromašnije kvintile (Svjetska banka, 2012b).

U svjetlu neefikasnosti postojećih naknada da dopru do siromašnih i smanje siromaštvo, Vlada Tadžikistana je 2011. godine pokrenula pilot program testiranja izvodljivosti uvođenja jedne konsolidovane naknade za socijalnu pomoć najsiromašnijim domaćinstvima, korištenjem indirektnog imovinskog cenzusa. Rezultati indikatora za indirektni imovinski cenzus su empirijski izvedeni iz Tadžičke ankete o životnom standardu uz primjenu "stepwise" regresione analize (vidi u donjem tekstu). Rezultati pilot evaluacije ukazuju da PMT bolje cilja siromašnija domaćinstva. Uprkos ograničenom razumijevanju programa u pilotskim oblastima, program je obuhvatio 22 procenata najsiromašnije kvintile. Štaviše, skoro pola korisnika pripadalo je u najsiromašnijih 20 procenata, u poređenju sa 23 procenta u oblastima gdje pilot nije sprovođen (Svjetska banka, 2012b).

**Tabela 5.** Tadžikistan: Rezultati bodovanja indikatora za PMT na osnovu "stepwise" regresije.

| Urbana područja | | Ruralna područja | |
|---|---|---|---|
| Varijabla | Ponder | Varijabla | Ponder |
| Log (veličina domaćinstva) | -0,5694 | Veličina domaćinstva = 0 do 3 | 0 |
| Imaju električni radijator | 0,2333 | Veličina domaćinstva = 4 do 5 | -0,2182 |
| Imaju hladnjak | 0,2135 | Veličina domaćinstva = 6 do 7 | -0,3063 |
| Ima kompjuter | 0,2354 | Veličina domaćinstva = 8 do 12 | -0,4412 |
| Ima satelitsku antenu | 0,2399 | Veličina domaćinstva = 13 ili više | -0,6043 |
| Ima auto ili kamion | 0,3137 | Električni radijator | 0,3441 |
| Broj djece ispod 15 godina strosti | -0,0253 | Auto ili kamion | 0,2203 |
| Sektor zaposlenja = Poljoprivreda, ribarstvo ili šumarstvo | 0,2389 | Satelitska antena | 0,1915 |
| Sektor zaposlenja = Industrija ili rudarstvo | 0,0427 | Plinska peć | 0,0801 |
| Sektor zaposlenja = Usluge (komunalne) | 0,1548 | Generator | 0,2033 |
| Sektor zaposlenja = Građevinarstvo | -0,0109 | Djeca do 15 godina starosti = 0 | 0 |
| Sektor zaposlenja = Javna uprava, zdravstvo ili obrazovanje | -0,0215 | Djeca do 15 godina starosti = 1 ili 2 | -0,1041 |
| Sektor zaposlenja = Prodaja ili usluge | 0,1141 | Djeca do 15 godina starosti = 3 | -0,2329 |
| Sektor zaposlenja = Ostalo | -0,0375 | Djeca do 15 godina starosti = 4 do 6 | -0,3391 |
| Obrazovanje nosioca domaćinstva = osnovno | -0,1727 | Djeca do 15 godina starosti = 7 ili više | -0,4688 |
| Obrazovanje nosioca domaćinstva = srednje | -0,0107 | Invalid I kategorije u domaćinstvu | -0,1054 |
| Obrazovanje nosioca domaćinstva = više | 0,1081 | Krovni materijal kuće = premaz možda je bolje obloga? Obloga je bolje | 0 |
| Krovni materijal kuće = lim, pločice, blato, betonski blok | -0,0846 | Krovni materijal kuće = slama; glina | -0,1865 |
| Krovni materijal kuće = slama | 0,2684 | Krovni materijal kuće = metal; crijep | -0,0249 |
| Oblast = sughd | 0,0038 | Oblast = Sughd | -0,1258 |
| Oblast = khatlon | 0,0526 | Oblast = Khatlon | -0,1448 |
| Oblast = RRP | 0,2395 | Konstanta | 56.923 |
| Oblast = GBAO | -0,0616 | | |
| Konstanta | 5,8783 | | |

*Izvor:* EuropeAid Project 2011.

I konačno, izbor graničnog nivoa ključan je da se utvrdi učinak PMT-a. Grosh i Baker (1995.) zaključuju da postoji tendencija da greške isključenja budu posebno visoke ako se ciljna grupa ograniči na 10 ili 20 procenata najsiromašnijih. Greška isključenja može se bitno smanjiti ako se poveća veličina ciljne grupe. U slučaju Sri Lanke, greška isključenja se smanjuje za 15 procentnih poena a greška uključenja za 4 procentna poena ako se poveća veličina ciljne grupe (Narayan i Yoshida, 2005.). U Egiptu je vlada naposlijetku odabrala granični nivo PMT-a bez greške isključenja, prihvatajući grešku uključenja od 34 procenata (Ahmed i Bouis, 2002.).

*b. Uklapanje modela PMT-a i testova osjetljivosti*

Posljedice svake odluke kad su u pitanju metode mogu biti dalekosežne. Uputno je obaviti analize osjetljivosti koje provjeravanju robusnost PMT po drugačijim specifikacijama za različite modele. U skladu sa gornjim elementima, testovi osjetljivosti obuhvataju procjenu odvojenih modela za donju polovinu stanovništva nasuprot modelu za cijelo stanovništva, za urbane i ruralne dijelove zemlje, a u slučaju BH za dva entiteta, FBiH I RS. Štaviše, moguće je razmisliti o kalibraciji štedljivijih ili izdašnijih modela regresije.

Koeficijent determinacije regresionog modela izražava koji se udio varijacije zavisne varijable, tj. u ovim primjerima obično siromaštvo po prihodima ili po potrošnji, može objasniti zamjenama koje se uključuju kao nezavisne varijable. Stoga to predstavlja znak koliko dati statistički model može objasniti. Model koji savršeno odgovara daje vrijednost 1; za poređenje, polazni model u Bosni i Hercegovini, zasnovan na podacima iz 2007. godine, ima

koeficijent determinacije od 049. Štaviše, koeficijent determinacije bio je 0,2 u armentskom modelu PMT-a,[10] i 0,62 u Gruziji (Svjetska banka, 2009c, str. 27).

Djelotvornost nekog modela se ocjenjuje po tome u kojoj mjeri on tačno određuje status siromaštva, očekivanom efektu smanjenja siromaštva ili troškovnoj efikasnosti. Samosvojstven nedostatak svake PMT formule je da je dizajnirana da u prosjeku tačno predviđa socijalni položaj, ali to neće uspjeti ni za jedno uključeno domaćinstvo. Svako predviđanje sadrži određeni stepen nesigurnosti koji se obično dalje ne uzima u obzir u PMTu (Coady i drugi, 2004a, str 54). Sa aspekta terminologije, Slater i Farrington (2009.) prave razliku između grešaka ciljanja u dizajnu i implementaciji, pri čemu se ove druge nazivaju greška uključenja i isključenja. U pogledu grešaka u dizajnu, stvarni status nekog domaćinstva sa aspekta siromaštva koji je obuhvaćen anketom se poredi sa predviđenim statusom siromaštva po modelu PMT.[11] Međutim, važno je zapamtiti da su i status siromaštva i modeli PMT izvedeni iz anketnih podataka. Kvalitet osnovnih anketnih podataka određuje pouzdanost rezultata, koji su u svakom slučaju tek procjene stvarne situacije.

Pojavljuju se dva tipa grešaka (v. tabelu 6): Prvo, domaćinstvo koje u stvarnosti nije siromašno po formuli se prognozira kao siromašno. U simulaciji obavljenoj u Kirgistanu sa podacima iz Kirgiske integralne ankete o potrošnji stanovništva (Kyrgyz Integrated Household Budgets Survey - KIHBS), korištena formula PMT pogrešno identifikuje oko 20 procenata ne-siromašnih domaćinstava kao siromašna. Drugo, stvarno siromašno domaćinstvo se smatra ne-siromašnim na osnovu prognoziranog socijalnog položaja domaćinstva.Ovo se dešava za jedno od četiri lica koja žive u siromaštvu. U pogledu krajnjeg siromaštva, samo sedam procenata ne-siromašnih se pogrešno identifikuju kao siromašni, ali više od polovine stvarno krajnje siromašnih ne bude identifikovano. Ovaj posljednji nalaz pokazuje da bi moglo biti posebno teško otkriti ko su krajnje siromašni među siromašnim (Svjetska banka, 2009d, str. 125).

**Tabela 6.** Poređenje stvarnog i prognoziranog statusa siromaštva, Kirgiska Republika, 2005.

| | Apsolutno siromašni po zamjenskoj varijabli (by proxy) | | | Izuzetno siromašni po zamjenskoj varijabli. | | | |
|---|---|---|---|---|---|---|---|
| Apsolutno siromaštvo | Ne-siromašni | Siromašni | | Krajnje siromaštvo | Ne-siromašni | Siromašni | |
| Ne-siromašni | 80,34 | 19,66 | 100 | Ne-siromašni | 92,83 | 7,17 | 100 |
| Siromašni | 24,79 | 75,21 | 100 | Siromašni | 52,42 | 47,58 | 100 |

*Izvor:* World Bank (2009d, str. 125).

I najzad, mogu se porediti ishodi koji se postižu primjenom PMT sa ishodima drugih mehanizama ciljanja. Na primjer, u Tadžikistanu je poređenje simulacija predložene formule PMT i geografskog ciljanja ukazuje da je PMT bolji i u identifikovanju siromašnih i ne-siromašnih domaćinstava, a i da je ukupna postignuta preciznost ciljanja bila 54 procenata u poređenju sa samo 24 procenata kod geografskog ciljanja (Svjetska banka, 2011b, str. 21).

[10] Obratite pažnju da je Armenija odredila indikatore i skorove na temelju mišljenja stručnjaka.

[11] U ovoj fazi, još jednom je bitno da je siromaštvo jasno definisano, tako da je moguće validno porediti stvarni i prognozirani status siromaštva. Na primjer, ako se tvrdilo da je PMT dizajniran da registruje multidimenzionalne aspekte siromaštva, poređenje sa stvarnim statusom siromaštva zasnovano na prihodima bilo bi manjkavo.

*c. Ograničenja*

Osnova za definisanje varijable i pondera kod indirektnog imovinskog cenzusa su podaci iz anketa sa domaćinstvima koji sadrže dovoljan nivo informacija o karakteristikama domaćinstava. Problemi i nejasnoće koje se pojavljuju treba prepoznati, posebno kod neuzoračkih grešaka i grešaka uzorka, pošto oni utiču na robusnost procjena.

**Tekstni okvir 1.** Greške u anketi

**Greške uzorka** jednostavno nastaju zbog činjenice da se ne vrši posmatranje cijele populacije, već samo jednog podskupa, tzv. uzorka. Ovo dovodi do izvjesne nesigurnosti kada se izvlače zaključci o čitavoj populaciji na temelju onog što se nalazi u datom uzorku.
**Neuzoračke greške** nastaju u raznim momentima tokom prikupljanja podataka, njihovog prečišćavanja i obrade (v. AusAID, 2011, str. 6; Ujedinjene Nacije, 2005, str. 186). Specifikacija podataka može da ne bude dosljedna ciljevima istraživanja, ili su upitnici, definicije ili uputstva nejasni. Definicije domaćinstva i članova domaćinstva su ponekad problematične, pošto domaćinstva nisu statični entiteti. Štaviše, greške nastaju i zbog manjkavih metoda intervjuisanja, ali i zbog nepreciznih informacija koje daju učesnici u anketi. Nedostatak kvalifikovanog terenskog osoblja i adekvatnog nadgledanja pogoršava ove probleme. Kasnije, nedovoljno prečišćavanje podataka da se isprave očite greške, pogrešno kodiranje ili tabulacija, i konačno greške tokom objavljivanja i prikaza sve dovode do neuzoračkih grešaka.

Jedna studija koja koristi podatke za Ruandu, Bangladeš i Šri Lanku ilustruje efekat greške uzorka na indirektni imovinski cenzus čija je formula izvedena iz regresione analize (AusAid, 2011, str. 20). Na temelju standardne greške regresionog koeficijenta, definiše se interval povjerenja koji predstavlja raspon vjerovatnih vrijednosti regresionog koeficijenta. U ovoj studiji, polazni scenario koristi regresione koeficijente kao pondere, dok donji i gornji granični scenariji primjenjuju vrijednosti donje i gornje granice sa pouzdanošću od 95%. Autori dokazuju da će se od sedam do jedanaest procenata domaćinstava tretirati drugačije kada se koriste donje ili gornje granične procjene nekog od koeficijenata, iako su sve ove vrijednosti vjerovatne.

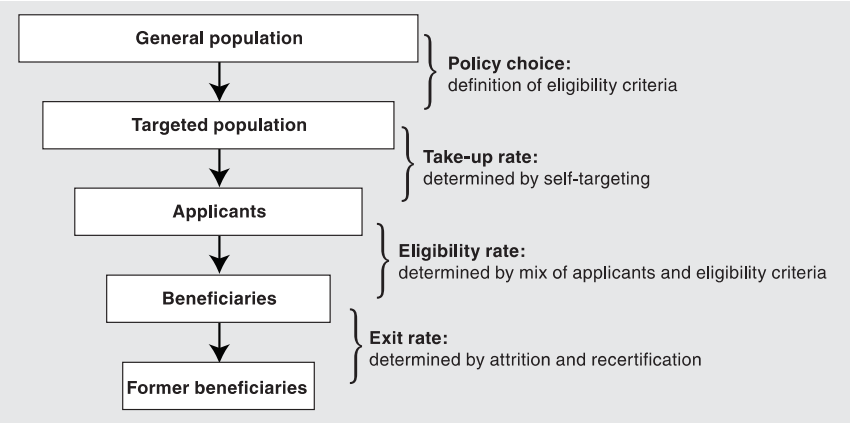
Primjer neuzoračke greške pojavljuje se kod prihoda u Anketi o potrošnji domaćinstava u Bosni i Hercegovini 2007. Prijavljeni prihodi će vjerovatno biti izrazito niži od stvarnih iz više razloga (Svjetska banka, 2009c, str. 24): prvo, pitanja o neformalnim i prihodima iz samozaposlenja nisu dovoljno detaljna, a međunarodna poređenja su pokazala do ovo vodi ozbiljnije nižem prikazivanju prihoda. Drugo, nema pitanja o prihodu od poljoprivrednih aktivnosti i, na kraju, period prisjećanja za prihode je jedna godina, a za potrošnju je dvije sedmice. Prema tome, vjerojatno je da će procjena prihoda biti niža u poređenju sa potrošnjom. Krajnji zaključak je da treba pažljivo i kritički ocijeniti kvalitet podataka koji se koriste za kalibraciju formule PMT, te da su čak i najbolji dostupni podaci samo aproksimacija koju prati znatan stepen nesigurnosti.

## *3 Implementacija PMT-a i drugi problemi u implementaciji*

Ključna naučena lekcija komparativne studije koju su radili Coady i drugi (2004b), studija slučaja u Latinskoj Americi (Castañeda i Lindert, 2005.) i nedavnih ocjena mreža socijalne zaštite u šest zemalja regiona ECA (Svjetska banka, 2012c), jest da je implementacija od

ogromne važnosti za učinak mreže socijalne pomoći, bez obzira na to koji mehanizam ciljanja se primjenjuje. Dobra implementacija programa ciljanja smanjuje greške isključenja (tj. obuhvat) i uključenja (tj. preciznost ciljanja), podržava troškovnu efikasnost, unapređuje transparentnost i na kraju, smanjuje nivo prevara i podstiče prihvaćanje i održivost. U Bosni i Hercegovini, sa njena dva entiteta Federacijom Bosne i Hercegovine i Republikom Srpskom, implementacija zaslužuje krajnju pažnju zbog fragmentacije administrativne i upravne strukture (Svjetska banka, 2010b, str 11), uključujući i jasnu raspodjelu institucionalnih nadležnosti. Grafikon 6 ilustruje faze ciljanja gdje je potrebna administracija.

**Grafikon 12.** Od populacije do korisnika: faze ciljanja




*Izvor:* Grosh i drugi. (2008, str. 106), adaptirano iz rada koji su napisali de Neubourg, Castonguay, i Roelen (2007.).

U prvoj fazi, definiše se ciljana populacija i beneficije koje program planira da ponudi: "koliko, pod kojim uslovima, koliko dugo, i kome" (Grosh i drugi, 2008, str. 106). Konkretni kriteriji kvalifikovanja biraju se u svjetlu njihove korelacije sa siromaštvom, budžetskih implikacija, u koordinaciji sa postojećim programima i zavisno od političke i administrativne izvodljivosti. Pod pretpostavkom da su sve ove odluke već donesene, i slijedeći odjeljci se fokusiraju na implementaciju indirektnog imovinskog cenzusa, naime na proces prikupljanja podataka i upravljanje bazom podataka; ažuriranje i recertifikaciju formule PMT; monitoring, verifikaciju i kontrolu prevara; na mehanizme za rješavanje žalbi i pritužbi; i konačno na institucionalne uloge i administrativne kapacitete.[12]

### *3.1 Proces prikupljanja podataka*

Organizacija procesa prikupljanja podataka razlikuje se od jedne zemlje od druge. Sve u svemu, ovaj proces treba da se zasniva na načelima transparentnosti, uključivanja siromašnih i ugroženih, troškovne efikasnosti i administrativne izvodljivosti. Pored toga, načelo dinamizma traži da registracija bude stalna i otvorena, posebno kad je cilj mreže socijalne pomoći "da ih uhvati kad [novi ili prolazno siromašni - komentar autora] padnu" (Castañeda i Lindert, 2005, str. 9). Dva glavna pristupa su podnošenje molbi na zahtjev i pristupi putem anketa (cenzusa) (v. tabelu 7).

[12] Ovaj odjeljak se uglavnom zasniva na studiji koju su radili Castañeda i Lindert (2005.), koji su ponudili detaljnu analizu naučenih lekcija na osnovu iskustava sa imovinskim cenzusom u Čileu, Kolumbiji, Kostariki i Meksiku, kao i sa neverifikovanim prihodovnim cenzusom u Brazilu i verifikovanim prihodovnim cenzusom u Sjedinjenim Američkim Državama. Usto, Grosh i drugi (2008.) se često pozivaju na Castañedu i Linderta (2005.), ali dodaju primjere iz zemalja regiona ECA.

**Tabela 7.** Relativne prednosti različitih procesa prikupljanja podataka

| | Anketni pristup | Pristup preko podnošenja molbi |
|---|---|---|
| Definicije | • Sva domaćinstva u datom području su intervjuisana i registrovana u skoro potpunom sistemu | • Oslanja se na domaćinstva da dođu u lokalnu kancelariju za socijalnu pomoć ili na određenu lokaciju da podnesu molbu za socijalnu pomoć |
| Prednosti | • Bolja mogućnost da se dosegnu najsiromašniji, koji su vjerovatno slabije informisani od ostalih<br>• Niži granični jedinični troškovi registracije zbog ekonomije obima kod troškova putovanja | • Niži ukupni troškovi zbog samoeliminacije ne-siromašnih iz procesa registracije (intervjui se vode sa manje ne-siromašnih porodica)<br>• Dinamičan, stalan pristup<br>• Demokratičniji: svako ima pravo da bude intervjuisan u bilo koje vrijeme<br>• Stalan proces pomaže da se razviju institucionalne strukture |
| Najpogodniji za | • Područja sa raširenim siromaštvom (više od 70 procenata stanovništva je siromašno)<br>• Homogena područja siromaštva (ruralna područja, urbane sirotinjske četvrti)<br>• Novi programi, kad se traži brzina | • Područja sa umjerenim ili niskim nivoom siromaštva<br>• Heterogena područja<br>• Program koji je dobro poznat i predstavljen u javnosti |
| Primjeri sistema ciljanja | • Brazil: Cadastro Unico<br>• Čile: Ficha CAS do devedesetih godina<br>• Kolumbija: SISBEN<br>• Kostarika: SIPO u siromašnim područjima<br>• Meksiko: registar za Oportunidades u ruralnim područjima | • Čile: Ficha CAS od ranih devedesetih<br>• Kolumbija: SISBEN<br>• Kostarika: SIPO<br>• Meksiko: registar za Oportunidades u urbanim područjima |

*Izvor*: Grosh i drugi. (2008, str. 109).

Proces podnošenja molbi na zahtjev smanjuje ukupne troškove u poređenju sa pristupom anketiranja, pošto samo-selekcija smanjuje udio intervjua sa domaćinstvima koja vjerovatno neće zadovoljiti kriterije kvalifikovanja. On je po prirodi dinamičniji jer omogućava domaćinstvima da se za registraciju prijave u bilo kom trenutku, a ne samo kad se sprovodi anketa. Otvoren proces podnošenja molbi još nudi i prednost da programi nisu tek zatvoreni ako se dostigne budžetski limit, već se kriteriji kvalifikovanja mogu prilagoditi na takav način da najsiromašnije grupe stanovništva i dalje budu ciljane. Nasuprot ovome, ova metoda traži da domaćinstva koja imaju mogućnost da se kvalifikuju znaju za ovaj program. Ako to nije slučaj, onda postoji rizik da će program propustiti da obuhvati domaćinstva sa najvećim potrebama. Dobra praksa u implementaciji umnogome doprinosi da se ovo izbjegne.

Posebno u slučaju pristupa s podnošenjem molbi, domaćinstva treba da imaju pristup svim potrebnim informacijama da bi realno ocijenila prednosti i troškove programa na individualnom nivou (Grosh i drugi, 2008, str. 107-109). Sa aspekta implementacije, ovo traži namjenjivanje dovoljno velikog budžeta za kampanje uključenja i informisanja, pri čemu treba imati na umu da upravo ciljna populacija može imati ograničen pristup izvorima informacija. Barijere u informisanju mogu nastati zbog nižeg obrazovnog nivoa, manje vjerovatnoće da će posjedovati televizor ili imati pristup novinama ili časopisima, ili zbog toga što žive u slabo uvezanim ruralnim i udaljenim krajevima. Na primjer, Armenija i Rumunija koriste kampanje javnog informisanja da osiguraju djelotvornu diseminaciju informacija o ovim programima (Svjetska banka, 2012c).

**Tekstni okvir 2.** Registracija na zahtjev u Albaniji[13]

Socijalna pomoć u Albaniji dizajnirana je da pruži novčanu pomoć i usluge socijalnog zbrinjavanja siromašnim, invalidima, djeci bez roditelja i starima. Čine je dva velika ogranka: (1) programi novčanih naknada i (2) usluge socijalnog zbrinjavanja za kvalifikovane kategorije. Programi novčanih naknada obuhvataju program socijalne pomoći koji primjenjuje metodu prihodovnog cenzusa i naziva se *Ndihma Ekonomika* (NE), mjesečne dodatke za siročad i invalide i kompenzacijske transfere za penzionere i njihove porodice.

Proces registracije za *Ndihma Ekonomika* zasniva se na registraciji "na zahtjev" pri čemu domaćinstva podnose molbu u kancelariji za socijalnu pomoć odgovarajuće komune ili opštine. I posjete kancelariji i kući koriste se za registraciju i verifikaciju podnesenih zahtjeva. Svaki potencijalni korisnik treba da se sastane sa socijalnim administratorom, koji provjerava da li su ispunjeni kriteriji za kvalifikovanje. Pored toga, nosilac domaćinstva podnosi "Izjavu o socijalno-ekonomskom položaju porodice" (Statement of Family Social-Economic Situation - FSES), koju potpisuju svi drugi članovi. Ova molba se podnosi uz više dokumenata koji potvrđuju socio-ekonomski status ili posjed nekretnina. Glavne provjere kod socijalnog administratora obuhvataju sve oblike vlasništva nad kapitalom, druge prihode i naknade koji se primaju, uslove života, status zaposlenosti i prijavljenost u slučaju nezaposlenosti, sadašnje mjesto boravka, vlasništvo nad poljoprivrednom zemljom, prethodne prijevarne radnje radi sticanja koristi od NE itd.

Dodatne barijere nastaju zbog transakcionih troškova koje mora snositi podnosilac molbe, kao što je dolazak u datu kancelariju, ili prikupljanje potrebnih dokumenata i potvrda. Programi u zemljama ECA razvili su niz načina da se smanje ovi transakcioni troškovi (Grosh i drugi, 2008, str. 110): u armenskom programu porodičnih naknada zbog siromaštva, podnosiocima molbi dokumenti se izdaju besplatno. Albanski program *Ndihme Ekonomika* omogućava nekim pojedincima, npr. invalidima ili majkama s malom djecom, da imenuju posrednike koji u njihovo ime obavljaju ove transakcije. I na kraju, Kirgiska Republika pravi razliku između podnosilaca molbe za jedinstvenu mjesečnu naknadu iz urbanih i ruralnih područja: ovi prvi treba da se prijave u kancelariji u svom rodnom gradu, a ove druge obilaze socijalni radnici koji im pomažu i da prikupe potrebnu dokumentaciju (CASE, 2005.).

Intervjui se mogu voditi ili u kancelariji ili u domovima podnosilaca molbi. Ova druga opcija omogućuje voditeljima intervjua ili socijalnim radnicima da odmah verifikuju karakteristike domaćinstva koje su obuhvaćene formulom indirektnog imovinskog cenzusa (Castañeda i Lindert, 2005, str. 13), što je jasna prednost u poređenju da puko oslanjanje na posjete kancelarijama. S druge strane, dolasci u kancelarije su obično troškovno efikasniji - bar iz perspektive vlade, iako ne s tačke gledišta podnosioca molbe. Često se proces registracije odvija u fazama, pa se informacija data u kancelariji provjerava kad socijalni radnici obiđu domaćinstvo. U ovakve primjere spada albanska *Ndihme Ekonomika* (Kolpeja, 2005.), armenska porodična naknada za siromašne (Harutyunyan, 2005.) i jedinstvena mjesečna naknada u Kirgiskoj Republici (CASE, 2005.). U litvanskom programu socijalne naknade, kućne posjete se zakazuju samo ako se otkriju nedosljednosti u podnesenim podacima (Zalimiene, 2005.).

U svakom slučaju, potreban je dosljedno visok nivo intervjua, npr. da se smanji nastajanje nekih od uzroka neuzoračnih grešaka. Između ostalog, ovo se osigurava jasnim smjernicama za kvalifikacije terenskog osoblja i supervizora, njihovom kontinuiranom obukom,

[13] Molimo pogledajte detaljniji opis date zemlje u Dodatku.

priručnicima i nadgledanjem visoke kvalitete, kao i poznavanjem lokalnog konteksta u smislu jezika i običaja (Castañeda i Lindert, 2005, str. 13).

Jasna komunikacija je ključna u svakoj fazi procesa prikupljanja podataka. Ovo uključuje da (ciljana) populacija bude dobro upoznata sa prednostima programa, instrumentom registracije i ključnim aspektima administrativnog procesa. Podnosioci molbe treba da jasno razumiju da sama registracija ne znači automatski i kvalifikovanje da se izbjegnu frustracije ili gubitak povjerenja. Komunikacija o politici povjerljivosti osigurava da intervjuisani razumiju koji podaci dolaze u obzir za dijeljenje s drugim agencijama i u koju svrhu. Na primjer, respondenti bi mogli biti skloni da prijave niže prihode ako sumnjaju da će se ti podaci koristiti i za poreske svrhe, jer strahuju od negativnih posljedica (Castañeda i Lindert, 2005, str. 15).

### *3.2 Upravljanje informacionim sistemima*

Čim se prikupe potrebne informacije o podnosiocima molbi i karakteristikama domaćinstva, ti podaci se unose u bazu podataka. Pitanje je u kojoj mjeri je izvodljivo da se uspostavi jedna nacionalna baza podataka o registrovanim domaćinstvima, koja olakšava upravljanje i omogućava državnim službenicima da korisnike prate na efikasan način, čime se smanjuje duplikacija i mogućnost prevara. Nedvosmislena identifikacija domaćinstava i pojedinaca postiže se dodjelom jedinstvenih identifikacionih brojeva. Ako iz nekog razloga jedinstveni identifikacioni broj ne postoji, u upitnicima se može tražiti da se za identifikaciju podnosioca molbe navede više identifikacionih brojeva, a onda mu se dodijeli novi broj. Nasuprot tome u zemljama Latinske Amerike i Kariba pojavilo se nekoliko problematičnih rješenja, npr. odbijanje domaćinstava bez identifikacionog broja, a to su obično najsiromašnija domaćinstva, ili dodjela novih brojeva svim novim domaćinstvima koja se prijave, što dovodi do čestih duplikacija (Castañeda i Lindert, 2005, str. 15-16).

I za registar i za ciljanje potrebna je definicija "jedinice pomoći". U Čileu (Ficha CAS), Kolumbiji (SISBEN) i Kostariki (SIPO), na primjer, pravi se razlika između domaćinstva i porodice (Castañeda i Lindert, 2005, str. 21). Ovakvo jasno razlikovanje je od posebne važnosti ako se jednim sistemom ciljanja podržava nekoliko programa koji su možda namijenjeni za različite jedinice pomoći. Štaviše, armenski program budžetskih transfera je od 1992. do 1998. bio usmjeren pojedincima a ne domaćinstvima, što je dovodilo do transfera ljudima koji su živjeli u domaćinstvima koja su u cjelini bila bolje stojeća, kao i do duplikacije transfera (Svjetska banka, 2002, str. 28).

Razlikuju se dva tipa registara koja služe u različite svrhe. Kad jedinstveni registar informacija o domaćinstvima obuhvata sva domaćinstva koja su podnijela molbu i sa kojima je obavljen intervju, programski-specifični spiskovi korisnika se sužavaju i prikazuju samo zaista kvalifikovana domaćinstva ili pojedince. Prvi tip registra služi za prikupljanje i verifikaciju karakteristika domaćinstva, utvrđivanje kvalifikovanosti i osiguravanje statistike za unapređenje planiranja i projekcija, a drugi je potreban da se odobre isplate, podrži vođenje slučajeva ili prati poštivanje uslova ili vremenskih rokova (Castañeda i Lindert, 2005, str. 18). U Gruziji je mogućnost podnošenja molbe za ciljanu socijalnu pomoć otvorena svim domaćinstvima, koja se onda registruju u bazi podataka o siromašnom i ugroženom stanovništvu. Nakon obilaska domaćinstva i više provjera, broj bodova "za ocjenu stanja potrebitosti" domaćinstva se izračunava automatski na osnovu zamjenske formule da se utvrdi da li ono dolazi u obzir za socijalnu pomoć (Svjetska banka, 2009e, str. 174). Krajem

2009, u jedinstvenoj bazi podataka bilo je registrovano 539.256 domaćinstava, ali samo 153.400 porodica je primalo socijalnu pomoć (UNICEF, 2010, str. 19).

Kompjuterske programe treba razviti tako da se lako mogu unijeti promjene u politici, otkriti duplikacije, omogućiti ažuriranje i re-certifikacija, te olakšati razmjena podataka između različitih nivoa uprave. Korištenje jednog kompjuterskog programa u raznim programima socijalne pomoći smanjuje troškove obuke osoblja i održavanja baza podataka; ovo ima dodatnu prednost da olakšava otkrivanje dupliranih naknada i djelotvornog uvezivanja korisnika sa drugim programima na koje imaju pravo po svojim karakteristikama. U Kirgiskoj Republici znatan dio siromašnih navodno dobija socijalne transfere iz više programa, ali je, zbog ograničenosti podataka, teško utvrditi tačan nivo preklapanja programa. Ove informacije mogle bi doprinijeti koherentnijem i racionalnijem dizajnu višestrukih programa (Tesliuc, 2004, str. 27). I na kraju, povjerljivost je neophodna da se osigura da se podaci ne distribuiraju na neodgovarajući način. Na primjer, ako se informacije daju nezavisnim, vanjskim istraživačima, treba osigurati anonnimnost obuhvaćenih domaćinstava ili pojedinaca (Castañeda i Lindert, 2005, str. 15, 18–19).

### *3.3 Ažuriranje i recertifikacija*

Kvalifikovanost datog podnosioca molbe utvrđuje se poređenjem prihoda, ili zbira bodova koji on ima po kompozitnom indeksu PMT, sa određenom graničnom vrijednošću. Uz standarde za uključenje u dati program, potrebno je uspostaviti i kriterijume koji ukazuju u kom trenutku dati korisnik izlazi iz programa. Ne samo da se ovim izbjegava držanje na spiskovima "fantomskih korisnika", već se oslobađaju i mjesta za nova siromašna domaćinstva (Grosh i drugi, 2008, str. 114). Međutim, to je odluka koju treba donijeti s pažnjom, jer prerano okončanje učešća domaćinstava u programu predstavlja rizik da se izgube svi eventualno pozitivni efekti koje je program proizveo.

Promjene u sastavu domaćinstva ili njegovoj lokaciji su, naravno, važne, posebno kod demografskog ili geografskog ciljanja. Ako su uključene u formulu PMT, takođe utiču i na ukupni zbir bodova, te ove informacije treba redovno ažurirati. Učestalost periodičnih procesa kontrola određuju razni faktori, kao što su empirijsko razmatranje dinamike siromaštva u datoj zemlji, osjetljivost sistema ciljanja na ovu dinamiku, troškovi periodičnih procesa kontrole, kao i administrativni kapaciteti (Grosh i drugi, 2008, str 114). Na primjer, u pogledu osjetljivosti na dinamiku siromaštva, sistemi ciljanja zasnovani na prihodovnom cenzusu traže češće ažuriranje nego što je slučaj kad se koristi indirektni imovinski cenzus. Prvi bolje reaguje na kratkoročne promjene socijalnog statusa nego procjene imovinskog cenzusa koje obuhvataju stabilnije karakteristike domaćinstava koje su u korelaciji sa siromaštvom.

**Tekstni okvir 3.** Maksimalno trajanje prava na naknadu u Srbiji[14]

Kao i drugim zemljama zapadnog Balkana, program novčane socijalne pomoći u Srbiji je relativno skroman. Obuhvat je ograničen. Mehanizam ciljanja zasnovan na prihodovnom cenzusu koristi niz administrativnih provjera i terenske posjete. Da bi se ograničila dugoročna zavisnost od ovog programa, novi Zakon o socijalnoj pomoći u Srbiji ograničava maksimalno

[14] Molimo pogledajte detaljniji opis date zemlje u Dodatku.

trajanje naknada FSA za korisnike koji su sposobni za rad (kao i za korisnička domaćinstva u kojima je većina članova sposobna za rad). U takvim slučajevima, naknada FSA je dostupna za do devet mjeseci u kalendarskoj godini (12 mjeseci). Pretpostavka je da takva osoba može naći zaposlenje u sezonskim ili drugim vrstama radova tokom preostala tri mjeseca. Prema tome, broj korisnika FSA opada tokom ljetnih mjeseci.

U zemljama regiona ECA, recertifikacija se obavlja najmanje jednom godišnje, npr. u Armeniji, koja primjenjuje indirektni imovinski cenzus za ciljanje porodičnih naknada za siromašne. U međuvremenu, od domaćinstava se traži da prijavljuju značajnije promjene u veličini domaćinstva, prihoda ili druge relevantne karakteristike (Harutyunyan, 2005.). U albanskom *Ndihme Ekonomika* kvalifikovanost se zasniva na prihodovnom cenzusu, a korisnici svakog mjeseca moraju prijavljivati svaku promjenu koja utiče na njihovu kvalifikovanost. Najmanje jednom godišnje korisnici moraju podnositi novu molbu (Kolpeja, 2005.). Za utvrđivanje kvalifikovanosti za svoj program jedinstvene mjesečne naknade, Kirgiska Republika primjenjuje prihodovni cenzus u kombinaciji sa kategorijskim ciljanjem. Recertifikacija se obično planira svakih šest ili dvanaest mjeseci, pri čemu je ad hoc recertifikacija moguća ako se dese bilo kakve promjene (Svjetska banka, 2009d, str. 79).

Pored recertifikacije domaćinstava, formula PMT traži i redovno ažuriranje, pošto se profil siromaštva često s vremenom mijenja. Na primjer, ovo se desilo u meksičkom programu *Oportunidades* (Azevedo i Robles, 2010, str. 8). Revizije su rađene i u Armeniji (Svjetska banka, 2009c, str. 18) i Čileu. U ovom drugom slučaju, krovni i zidni materijali, pristup pitkoj vodi i odvodu otpadnih voda, ali i prosječan broj godina obrazovanja izgubili su svoj diskriminatornu snagu i isključeni su iz ažurirane formule. Pored toga, ranije su prihodi bili uključeni, ali su eliminisani zbog nepouzdanosti, a i zato što nisu doprinosili eksplikatornoj snazi novog modela (Castañeda, 2005, str. 36–37).

### *3.4 Monitoring, verifikacija i suzbijanje prevara*

Monitoring, verifikacija i suzbijanje prevara su ključna pitanja koja treba ugraditi u dizajn i implementaciju svakog sistema ciljanja, tim prije ako je prikupljanje podataka decentralizovano (Grosh i drugi, 2008, str. 122). Da bi se garantovala dosljednost i transparentnost, intervjue koji se vode ili na terenu ili u kancelarijama treba nadgledati. Jedan instrument kontrole kvaliteta su ponovni intervjui na nasumičnom uzorku. S jednim nasumičnim uzorkom domaćinstava obavi se intervju po drugi put da se prikupljene informacije provjere i da se otkriju prevare, bilo na strani podnosilaca molbe ili nadležnog lokalnog organa. Ovo ima dodatnu svrhu da motiviše transparentnost procesa prikupljanja podataka na opštinskom nivou i kao politička alatka, jer pokazuje da savezna vlada ima odgovoran pristup, prati implementaciju i sprovodi procedure (Castaneda i Lindert, 2005, str. 31-32). Na primjer, u Sjedinjenim Američkim Državama je u okviru programa bonova za hranu uspostavljen opsežan sistem kontrole kvaliteta.

Za provjeru informacija koje daju podnosioci molbe na raspolaganju stoji širok spektar mogućnosti (Grosh i drugi, 2008, str. 111-113). Na primjer, podnosioci molbe mogu dostavljati papirne primjerke dokumenata kojima se potvrđuju ranije date izjave. Kako je gore opisano, razne zemlje su implementirale različita rješenja da bi se u ovakvim slučajevima transakcioni troškovi održali na razumnom nivou, npr. u Kirgiskoj Republici, gdje socijalni radnici prikupljaju potrebne dokumente za ruralne podnosioce molbe (CASE, 2005.) Pored toga, socijalni radnici veoma redovno obavljaju kućne posjete, bilo da su u datoj molbi utvrđene nedosljednosti, ili po automatizmu. Sama formula PMT je namjerno zasnovana na

lako uočljivim karakteristikama domaćinstava koje socijalni radnik može provjeriti a da ne naiđe na značajnije prepreke. Druga mogućnost je provjeravanje sa trećim licima. Ovo može biti u zajednici gdje podnosilac molbe živi, na osnovu logike da članovi zajednice dovoljno dobro poznaju međusobni socijalni status (Grosh i drugi, 2008, str. 112). Ipak, treba izbalansirati informacione prednosti koje bi zajednice mogle imati sa opasnošću da bi elite mogle povući većinu naknada (Alatas, Banerjee, Hanna, Olken i Tobias, 2010.).

U slučaju kada su registar domaćinstava ili jedinstvena baza podataka relativno dobro razvijeni, informacije se mogu provjeriti i sa drugim agencijama. Evidentno, za ovakav tip verifikacije potreban je jedinstven, nedvosmislen vid identifikacije za svako domaćinstvo i/ili pojedinca, kao i politike osiguranja povjerljivosti u ovom procesu, kao što je već ranije spomenuto. Armenija koristi druge vladine baze podataka da se provjeri postoje li nedosljednosti u podnesenim molbama; a Albanija redovno dobija ažurirane spiskove iz registra nezaposlenih radi provjere podnesenih molbi (Grosh i drugi, 2008, str. 112; Harutyunyan, 2005.). Drugi načini za monitoring i verifikaciju informacija su angažman građana kroz mehanizme građanskog nadzora i socijalne kontrole (vidi Castaneda i Lindert, 2005, str. 32). Sve u svemu, monitoring i nadzor se jačaju korištenjem više instrumenata (Grosh i drugi, 2008, str. 122).

Za indirektni imovinski cenzus bitan aspekt je da li formula za bodovanje treba da bude javna. Time se unapređuje transparentnost, a utvrđivanje kvalifikovanosti izgleda manje tajnovito i arbitrarno, pošto podnosioci molbe mogu provjeriti da li je njihov zbir bodova ispravno sračunat. Štaviše, adekvatnost same formule postaje tema za razmatranje u javnosti (Coady i drugi, 2004a, str 53). U Armeniji je formula objavljena, ali u matematičkom obliku. Kvalitativno istraživanje je ukazalo da ovo nije dovelo do boljeg razumijevanja indirektnog imovinskog cenzusa, iako je nivo obrazovanja u Armeniji načelno visok (Gomart, 1998, u zborniku Coady i drugi, 2004a, str 53). U Čileu je objavljivanje formule PMT napušteno nakon ažuriranja 1987, pošto se pojavila zabrinutost da detaljno poznavanje kriterija podstiče prevare i potkupljivanje socijalnih radnika (Grosh, 1994, str 71).

### *3.5 Mehanizmi za rješavanje žalbi i pritužbi*

Bilo da je do greške zaista i došlo ili ne, svaki program treba da uspostavi mehanizme za rješavanje žalbi i pritužbi ako ne želi da rizikuje gubitak povjerenja, percepcije pravičnosti i reputaciju. Po Groshu i drugima (2008.), ovi mehanizmi imaju najmanje tri cilja, naime rješavanje problema o pravilima programa, minimiziranje troškova i za program i za podnosioce molbe odnosno korisnike i jačanje percepcije da je program pristupačan, transparentan, pravičan i brz. Do žalbi dolazi u bilo kom momentu implementacije sistema ciljanja domaćinstava, ali će one najverovatnije biti povezane sa kriterijima za kvalifikovanje. U tom pogledu, pritužbe se pojavljuju ako neko smatra da je on ili ona greškom isključen (greška isključenja) ali i ako neko smatra da je neko domaćinstvo pogrešno uključeno (greška uključenja).

Što je viši upravni nivo koji se bavi rješavanjem žalbi, to su veći troškovi i za podnosioca molbe odnosno korisnika, i za sam program (Grosh i drugi, 2008, str. 116). Jasna komunikacija i transparentnost tokom procesa podnošenja molbe poboljšavaju upoznatost podnosilaca molbe i korisnika o kriterijima za kvalifikovanje i pravilima programa i doprinose potpunom izbjegavanju nekih problema. Štaviše, i korisnici, ali i odbijeni podnosioci molbe, treba da jasno znaju ko je osoba za kontakt ako osporavaju odluku o kvalifikovanosti, ili za neispravnu obradu uplata. Mehanizam za rješavanje žalbi može biti zajednički za više javnih

službi, ili može biti samostalni mehanizam za određeni program. Idealno, većinu problema rješava davalac usluga na terenu, kao što su materijalne greške, nerazumijevanje pravila programa, ili provjere i verifikacija informacija. Ovo je klijentima lako dostupno, ali i najmanje košta, i pomaže da se u budućnosti izbjegnu greške na ovom nivou.

Ako se problemi ne riješe na prvom nivou, treba da bude dostupan drugi nivo koji rješava žalbe. Posvećivanje velike pažnje žalbama rezultira značajnim signalima o sistematskim manjkavostima u dizajnu i implementaciji sistema ciljanja, i pomaže u detektovanju nekompetentnosti, nemara ili zloupotrebe položaja, do kojih može doći u kancelarijama na terenu. Viši, ili nezavisni žalbeni nivoi uključuju kancelarije na slijedećem upravnom nivou ili specijalizovane ogranke osnovane za rješavanje žalbi. Sve žalbe treba obraditi u određenom vremenskom roku i uključiti objašnjenje odluke (Grosh i drugi, 2008, str 117). Zadnji, i obično najskuplji, nivo podnošenja žalbe su sudske tužbe, koje na kraju krajeva mogu čak uzrokovati promjene u pravilima programa (Grosh i drugi, 2008, str. 117).

Iz iskustava raznih zemalja pojavila su se neka perspektivna rješenja (Grosh i drugi, 2008, str. 117-118). Jasna komunikacija, kao i administrativna preciznost, doprinose sprečavanju žalbi. Agenti u zajednici, tj. korisnici koji su prošli određene dodatne obuke, pomažu u pojašnjavanju kriterija kvalifikovanosti. "Call" centri obavljaju istu funkciju, i njihova odgovornost može se kretati od objašnjavanja pravila do pristupa dosjeima i ispravljanja grešaka. Armenija je osnovala savjete za socijalnu podršku radi rješavanja pritužbi o greškama isključenja. Ove savjete čine lokalni službenici iz socijalnog sektora i predstavnika NVO, koji razmatraju slučajeve kad su molbe odbijene (Harutyunyan, 2005.). Meksički *Oportunidades* je jedan od nekoliko programa u kom se teži smanjenju grešaka uključenja i isključenja putem dostavljanja nacrta spiskova korisnika odborima u zajednici radi razmatranja. Međutim, u praksi se predlaže mali broj promjena, posebno kad je u pitanju skidanje nekog domaćinstva s takvih spiskova, moguće zbog straha od negativnih posljedica po lice koje iznese takav prijedlog. Iz tog razloga u El Salvadoru ovaj posao rade nevladine organizacije (Grosh i drugi, 2008, str. 118).

### *3.6 Administrativni kapaciteti i institucionalne nadležnosti*

Uspješna implementacija indirektnog imovinskog cenzusa često zavisi od postojećih administrativnih kapaciteta i načina na koje su podijeljene institucionalne nadležnosti. Pošto u dizajnu i implementaciji jednog sistema ciljanja učestvuju brojni akteri, "utvrđivanje jasnih institucionalnih uloga je ključno za uspjeh sistema ciljanja domaćinstava" (Castaneda i Lindert, 2005, str. 28). Ovo traži pažljivo razmatranje u kontekstu fragmentarnog karaktera upravnih i vladajućih struktura Bosne i Hercegovine.

**Tabela 8.** Primjer modela s centralizovanim dizajnom i upravljanjem i decentralizovanim prikupljanjem podataka

| Federalni | Državni (oblasni) | Opštinski |
|---|---|---|
| ▪ Dizajniranje sistema i kriterija<br>▪ Razvijanje zajedničkog kompjuterskog programa (u konsultaciji s različitim postojećim programima i nivoima vlasti) | ▪ Tehnička pomoć, obuka, IT podrška opštinama<br>▪ Nasumične revizije, kontrola kvaliteta i suzbijanje prevara (QCRs)<br>▪ Konsolidacija podataka na | ▪ Prikupljanje podataka bilo putem primanja molbi ili metodom ankete, u okviru federalnih pravila i procedura (idealno uz finansiranje iz federalnih izvora ili podjelu |

| | | |
|---|---|---|
| ▪ Provjera podataka<br>▪ Nasumične revizije, kontrola kvaliteta i suzbijanje prevara (QCRs)<br>▪ Konsolidacija podataka na federalnom nivou: glavna federalna baza podataka<br>▪ Odabir korisnika za federalne programe<br>▪ Vršenje isplata (posredstvom bankarskog sistema)<br>▪ Konsolidacija nacionalnog registra korisnika federalnih, oblasnih i lokalnih programa | federalnom nivou: glavna federalna baza podataka<br>▪ Prečišćavanje podataka, provjera<br>▪ Odabir korisnika za oblasne programe<br>▪ Razmjena spiskova korisnika na federalnom i oblasnom nivou sa lokalnim i federalnim agencijama. | troškova)<br>▪ Unos podataka, verifikacija, prečišćavanje, provjere<br>▪ Često ažuriranje, ispravke<br>▪ Konsolidacija podataka na opštinskom nivou: glavna baza podataka na opštinskom nivou<br>▪ Odabir korisnika za opštinske programe<br>▪ Razmjena spiskova korisnika na federalnom i lokalnom nivou sa federalnim i oblasnim agencijama |

*Izvor:* Castañeda i Lindert (2005, str. 30).

Tabela 8 prikazuje stilizovan primjer kako se institucionalne nadležnosti mogu rasporediti po različitim nivoima uprave. Konačna podjela zadataka zavisi od konteksta date zemlje i stepena decentralizacije. U ovom primjeru, konkretan dizajn samog sistema, uključujući izbor varijabli i pripadajućih pondera u formuli PMT za bodovanje, postavljen je na federalnom nivou. Ovo obuhvata i pripremu materijala za obuku, priručnika i zajednički kompjuterski program. Po ovim federalnim pravilima, podaci se prikupljaju na opštinskom nivou. Nakon unosa i obrade podataka i moguće nakon prvih provjera na nivou oblasti, podaci se dostavljaju oblasnom nivou. U tom momentu, vrši se dodatno prečišćavanje i provjera podataka, prije nego što se dalje usmjere ka bazi podataka na nivou zemlje. Obavlja se i verifikacija sa federalnim bazama podataka, kao i priprema glavne baze podataka. Pored toga, postojaće mehanizmi kojima će se osiguravati monitoring i kontrola kvaliteta na federalnom nivou. Potrebno je pažljivo i izričito utvrditi u kojoj mjeri koji nivo pokriva koje troškove.

Zavisno od konkretnih zadataka, potrebne kvalifikacije za službenike u programu variraju, a varijacije su velike i od jedne do druge zemlje (Grosh i drugi, 2008, str 119-120). Za PMT, prikupljanje podataka može se ugovorno prenijeti na profesionalne anketne timove koji su kvalifikovani za obavljanje intervjua, ali im možda nedostaje poznavanje programa i kriterija kvalifikovanja. Sa svoje strane, ovo može biti poželjna karakteristika ako je potrebno ocjenjivati granične slučajeve. Još jedan bitan element je da osoblje dobro obučeno u vještinama komunikacije doprinosi izbjegavanju sukoba, poboljšanju pridržavanja uputstava i izgradnji povjerenja u program. Sve u svemu, dobra obuka za službenike koji se primaju u program je važan dio izgradnje administrativnih kapaciteta. U slučajevima gdje osoblje za primjenu novog programa ima samo ograničeno vrijeme i kapacitete, može imati smisla da se ponovo razmotri dizajn mehanizma ciljanja da se izbjegnu pretjerane greške u implementaciji. Mjere koje su doprinijele boljoj administraciji sistema ciljanja domaćinstava u zemljama ECA uključuju opsežniju obuku osoblja, kao i obezbjeđenje dovoljne dokumentacije za osoblje (Grosh i Tesliuc, 2005.).

### *3.7 Transparentnost i troškovi*

Transparentnost je bitna u svim fazama procesa implementacije, tj. u procesu prikupljanja podataka, upravljanju informacionim sistemom, mehanizmu provjere kvalifikovanosti, institucionalnim aranžmanima i mehanizmu monitoringa, verifikacije i nadzora. Na osnovu

studija slučaja za četiri zemlje Latinske Amerike koje primjenjuju indirektni imovinski cenzus, Castaneda i Lindert su identifikovali slijedeće faktore koji doprinose visokoj, odnosno niskoj, transparentnosti (2005, str. 46-47, tabela 16): Prvo, kod prikupljanja podataka, visoka transparentnost se postiže otvorenim registrom u koji se prijavljuje na zahtjev, dobro dokumentovanim procedurama i priručnicima, adekvatno obučenim voditeljima intervjua, nadgledanjem voditelja intervjua i revizijom obavljenih intervjua. Nasuprot tome, zatvoreni registar dovodi do rjeđeg upisa, a u ovom pogledu štetan je nedostatak smjernica za rad i priručnika.

Drugo, transparentnost upravljanja informacionim sistemom se olakšava korištenjem jedinstvenog identifikacionog broja, sistema za eventualno čak i automatizovane provjere dosljednosti i tačnosti i redovno ažuriranje i recertifikacija. Nepostojanje baze podataka na nivou zemlje, dupliranje do koga dolazi zbog nepostojanja jedinstvenih identifikacionih brojeva i mogućnost vršenja nedokumentovanih promjena i manipulacija bazom podataka čine informacione sisteme netransparentnim. Treće, transparentne metode provjere kvalifikovanosti zasnivaju se na detaljno dokumentovanim kriterijima kvalifikovanosti i na kvalitetnom upitniku, na detaljnoj provjeri izjava, automatizovanju odluka o kvalifikovanosti i formalnim procedurama kojima se rješavaju pritužbe i žalbe. Odsustvo bilo kojeg od ovih faktora dovodi do niske transparentnosti. I konačno, centralizovane smjernice za prikupljanje podataka i utvrđivanje kvalifikovanosti, centralizovano upravljanje bazom podataka, formalna revizija i automatske provjere jačaju transparentnost institucionalnih aranžmana, kao i monitoring i evaluaciju. Nasuprot tome, ako nema evaluacije rezultata ciljanja, i ako ne postoje sistemi za izvođenje vanjskih revizija baza podataka na nasumičnom uzorku, to negativno utiče na transparentnost.

U pogledu troškova, ključni aspekt za razmatranje dizajna i implementacije svakog sistema ciljanja domaćinstava je koliko će nešto koštati, u poređenju sa svojim potencijalom da dovede do finansijskih ušteda (Gassmann, 2011.). Time se ukazuje da, u najgorem slučaju, administrativni troškovi isključenja nekvalifikovanog domaćinstva mogu nadmašiti iznos same naknade (Samson, Van Nieker i Mac Quene, 2010, str. 112). SVaka odluka, polazeći od izbora mehanizma ciljanja, podrazumijeva različite troškove za razuličite aktere koje treba odvagnuti nasuport mogućih ušteda zbog ciljanja socijalnih transfera.

Bitno je da troškovi ne obuhvataju samo neposredne administrativne rashode, već i privatne troškove na nivou pojedinca ili domaćinstva, kao i motivacijske, socijalne i političke troškove (v. Samson i drugi, 2010.). Studije slučaja vođene u šest zemalja Latinske Amerike i u Sjedinjenim Američkim Državama ukazuju da se administrativni troškovi razlikuju zavisno od mehanizma ciljanja (v. Castaneda i Lindert, 2005, str 42). Kao što se i očekivalo, najveći troškovi su kod provjeravanog prihodovnog cenzusa u SAD. Kad je u pitanju indirektni imovinski cenzus, administrativni budžeti u četiri analizirane zemlje, Čileu, Kolumbiji, Kostariki i Meksiku se razlikuju.

Ima više faktora koji objašnjavaju razlike u administrativnim troškovima za PMT: Ukupni rashodi za prikupljanje podataka su veći za kvazi-sveobuhvatne ankete nego kod samoinicijativnog prijavljivanja za sudjelovanje u anketi, mada su u ovom drugom slučaju granični troškovi viši. Pored razlika u troškovima na plate od jedne do druge zemlje, razliku uzrokuje i kvalifikovanost voditelja intervjua, kao i disperzija intervjuisane populacije u udaljenim krajevima. Štaviše, razmatranje troškovne efikasnosti treba da uzme u obzir administrativne troškove u odnosu na visinu naknade. Nesumnjivo je da potrošiti isti iznos na ciljanje kao i na samu socijalnu naknadu nije efikasno. Veća troškovna efikasnost postiže se i

primjenom iste metode ciljanja na nekoliko programa, pošto ovo omogućuju veći nivo ekonomije obima (Grosh i drugi, 2008, str. 93-94). Ovo je bila ključna naučena lekcija u nekoliko zemalja ECA (Grosh i Tesliuc, 2005), a to se koristi, na primjer, u Gruziji, koja primjenjuje indirektni imovinski cenzus za utvrđivanje kvalifikovanosti. Porodice čiji je zbir bodova ispod 70.001 imaju pravo na besplatne vaučere za zdravstvenu zaštitu, a porodice čiji je zbir bodova ispod 56.001 pored toga su kvalifikovane i za novčanu pomoć (UNICEF, 2010, str. 19). I na kraju, ukupni administrativni troškovi teže da budu veći u inicijalnoj fazi programa, što je, na primjer, uočeno u Meksiku, dje su administrativni troškovi, spali sa 51 procenata na 6 procenata ukupnog budžetskog programa u prvih sedam godina (Grosh i drugi, 2008, str 94)

Drugo, privatne troškove po definiciji snosi domaćinstvo i oni smanjuju neto korist od socijalnih transfera. Međunarodno uporedivi dokazi o privatnim troškovima su prilično rijetki. U Armeniji, među razloge zašto se ljudi ne prijavljuju za socijalnu pomoć obuhvataju nedovoljnu informisanost o načinu rada sistema, nedostatak sredstava za putne troškove, plaćanja "ispod stola" radi registracije i nemogućnost da se stoji u dugim redovima, npr. zbog invaliditeta ili trudnoće (Gomart, 1998: U publikaciji Svjetske banke, 1999, str. 52). U Gruziji je glavni razlog zbog kog se siromašne porodice ne prijavljuju za ciljanu socijalnu pomoć uključuje strah da ocjena neće biti pravilno sprovedena, ali i nedovoljno poznavanje postupka registracije. Samo mali dio domaćinstava prijavljuje barijere koje se odnose na fizička ograničenja, put ili prikupljanje potrebnih dokumenata (UNICEF, 2010, str. 23).

Treće, smatra se da će motivacioni troškovi biti manji problem za PMT nego za prihodovni cenzus i samo-ciljanje kroz javne radove (Grosh i drugi, 2008, str. 96). Pošto PMT nije neposredno zasnovan na ocjeni prihoda, očekuje se da će negativna motivacija za rad biti manja nego kod prihodovnog cenzusa. Ali je moguće da, kao četvrta stavka, da uključenje u ovakav program izaziva socijalne troškove, na primjer zbog stigmatizacije. Učešće u ovakvom javnom programu može dovesti do pojave osjećanja srama, a važnost ovog aspekta varira, dijelom u vezi s tim kako se program percipira u javnosti. Dokaz o ovom pitanju pojavio se u Armeniji, gdje su reklame u kojima se izričito naglašavalo da su siromašni ciljna grupa rezultirale strahom od socijalne stigme. U Bugarskoj su učesnici u programu javnih radova doživjeli nošenje reflektujućih sigurnosnih prsluka kao stigmatizaciju, iako im je svrha bila njihova bezbjednost. Nasuprot tome, dio nekadašnjeg jamajkanskog programa bonova za hranu koji se odnosio na zdravlje majki i djece pripremio je reklamu u kojoj se prijavila žena jednog ministra da bi se istakla univerzalnost programa i umanjila društvena stigma. Stoga treba odvagnuti u kojoj mjeri je potrebno podsticati samo-izbor podnosilaca molbe - s jedne strane, može se smanjiti greška uključenja, ali s druge, domaćinstva s najvećim potrebama mogu se obeshrabriti da podnesu molbu (Grosh i drugi, 2008, str. 96).

I na kraju, politički troškovi nastaju kad stepen i metoda ciljanja vode političkim reakcijama, na primjer kad utiču na političku podršku glasača i interesnih grupa. Dokaza je malo i mnoge rasprave o ovom aspektu ostale su nerazriješene (Grosh i drugi, 2008, str. 97), ali analiza opštinskih izbora u Brazilu je vrlo značajna u ovom pogledu: Vjerovatnoća ponovnog izbora gradonačelnika porasla je kada je implementacija programa *Bolsa Familia* u datom gradu garantovala male greške uključenja i isključenja, funkcionalne mehanizme društvene kontrole i veće efekte, tj. kad je zadovoljila kriterije "dobrih" rezultata (De Janvry i drugi, 2005.).

## *4 Zaključne primjedbe*

Bosna i Hercegovina se izdvaja među zemljama regiona ECA kao zemlja čija je potrošnja na programe socijalne pomoći među najvećima. Između 2006. i 2008. godine, ona je u prosjeku trošila 4 procenata BDP-a na socijalnu zaštitu, čime je bila ispred većine zemalja u regionu, izuzev Hrvatske, i primjetno iznad prosjeka EU. Međutim, izdašna potrošnja nije imala za rezultat visok obuhvat najsiromašnije kvintile stanovništva. Iz istorijskih razloga, znatan dio socijalnih naknada su programi zasnovani na pravima, za razliku od programa zasnovanih na potrebama (Svjetska banka, 2009c), tj. kvalifikovanost se ne utvrđuje prema stanju potrebe, već po stečenim pravima. Programi zasnovani na pravima uključuju naknade ratnim veteranima i porodicama poginulih, što odražava post-konfliktno stanje, dok je mnogo manji dio resursa usmjeren u socijalnu pomoć uslovljenu prihodovnim cenzusom i dječiji dodatak (Svjetska banka, 2009c, str. 3-5).

U svjetlu predviđene reforme civilnih naknada iz budžeta, ovaj rad je razmatrao argumente za i protiv raznih mehanizama ciljanja i prikupio je argumente iz raznih zemalja u (širem) regionu. U većini zemalja regiona, kvalifikovanost za budžetske transfere se zasniva na pravilima ciljanja koja imaju za cilj da naknade usmjere prema siromašnim i ugroženim grupama stanovništva. Ciljanjem se teži maksimalno povećati obuhvat siromašnih. To je način da se, s obzirom na ograničena sredstva, poveća nivo naknada za siromašne ili da se, pri postojećem nivou naknada, smanji potražnja od budžeta. Međutim, i ciljanje ima svoju cijenu. Ono može dovesti do porasta administrativnih troškova i gubitka efikasnosti zbog grešaka u ciljanju. Ono dalje može proizvesti političke, socijalne i motivacijske troškove.

U okviru skupa metoda ciljanja, indirektni imovinski cenzus je primjer individualnih ocjena, pri čemu se životni standard domaćinstava ocjenjuje na temelju skupa indikatora koji posredno odražavaju socijalni položaj tih domaćinstava. PMT je posebno pogodan u situacijama gdje postoji velika neformalna ekonomija, naturalna poljoprivreda ili znatan priliv transfera iz inostranstva. Ovi faktori čine zvanične prihode od plata i penzija manje djelotvornim u utvrđivanju kvalifikovanosti domaćinstava za socijalne transfere. S druge strane, PMT zahtijeva postojanje redovnih i pouzdanih podataka iz anketa sa domaćinstvima, pošto se model obično izvod empirijski.

Uvođenje PMT-a je potencijalna alternativa sadašnjem prihodovnom cenzusu i moglo bi unaprijediti učinak ciljanja kod civilnih socijalnih naknada u BiH. Ex-ante analiza politika uz korištenje podataka najnovije Ankete o potrošnji domaćinstava (2011.) i uz primjenu statičkih mikrosimulacija, daće ocjenu ove mogućnosti kroz poređenje različitih metoda ciljanja.

*Dodatak A: Komparativni pregled mehanizama ciljanja zasnovanih na individualnoj ocjeni*

**Tabela A 1.** Komparativni pregled prihodovnog, indirektnog imovinskog i hibridnog prihodovnog-imovinskog cenzusa

| | Podaci | Kriteriji kvalifikovanosti | Prednosti/nedostaci | Odgovarajuće okolnosti |
|---|---|---|---|---|
| **Prihodovni cenzus (Means-testing - MT)** | • Samoprijavljeni prihodi i imovina prikupljeni putem intervjua<br>• Potvrđeno certifikacijom, iz javnih informacija i/ili provjerama | • Prihodi < od nivoa praga prihoda<br>• Ponekad se uspostavlja viši nivo praga za "izlazak" iz programa. | Može biti vrlo precizan (posebno sa verifikacijom); usto, bolje reaguje na prolazne promjene (npr. u krizi).<br>Administrativno zahtjevan; traži visok nivo posmenosti i dokumentovanja ekonomskih transakcija (najbolje prihoda); problematičan kad postoji neformalnosti; potencijal za demotivaciju rada. | • Prikazani prihodi se mogu potvrditi ili se nekim oblikom samo-elekcije ograničava da neciljne grupe podnose molbe.<br>• Administrativni kapacitet je visok.<br>• Prednosti za primaoce su dovoljno velike da opravdaju troškove sprovođenja prihodovnog cenzusa.<br>• Primjeri: većina zemalja OECD (npr. Australija, Francuska, V. Britanija, SAD) |
| **Indirektni imovinski cenzus (Proxy means-testing - PMT)** | • Prikupljanje podataka o indikatorima putem intervjua.<br>• Opcija: potvrda upisanih domaćinstava u zajednici .<br>• Nasumične provjere radi potvrde informacija na nivou domaćinstva. | • Multidimenzionalni indeks uočenih karakteristika zasnovanih na podacima Ankete o potrošnji domaćinstava (HBS).<br>• Zbroj bodova < α+βX+βX+βX<br>• Za razne programe mogu se koristiti različiti pragovi. | Koristan u situacijama kad je prisutan visok nivo neformalnosti; lako uočljive karakteristike domaćinstva; manji potencijal za negativnu motivaciju pri traženju zaposlenja; omogućava da se obuhvate multidimenzionalni aspekti siromaštva (ne samo siromaštvo u pogledu prihoda).<br>Administrativno zahtjevan; može biti potrebno redovno mijenjati kriterije kvalifikovanosti kako ljudi uče da "varaju" sistem; ne registruje promjene brzo (sporije reaguje u krizi ili druge brze promjene ekonomskih okolnosti); inherentna nepreciznost na nivou domaćinstava; težak za komunikaciju u javnosti pošto njegove odluke mogu nekima izgledati nejasne ili proizvoljne. | • Relativno visoki administrativni kapaciteti.<br>• Programi namijenjeni da se ublaži hronično siromaštvo u stabilnim situacijama.<br>• Primjenljiv za velik program ili za nekoliko programa, da bi se maksimizirao povrat na iznos fiksnih troškova.<br>• Primjeri: prvo je razvijen u Čileu, zatim široko korišten u Latinskoj Americi. Proširio se u druge dijelove svijeta, npr. Armeniju, Gruziju, Indoneziju, Filipine i Turska. |
| **Hibridni cenzus (Hybrid means-testing -** | • Kombinacija gorenavedenih metoda.<br>• Ili kombinacija bilo | | Može biti vrlo precizan; optimizira korištenje informacija; moguć uz postojanje neformalnosti; manje negativne motivacije za traženje zaposlenja; Objektivan i potvrdiv; reaguje na promjene (npr. u vrijeme krize). | • Vidi iznad.<br>• Model se razvija u nekim zemljama u tranziciji, npr. u Bugarskoj, Kirgiskoj Republici, Rumuniji. |

| | | | | |
|---|---|---|---|---|
| **HMT)** | MT ili PMT sa kategorijskim filterima | | Administrativno zahtjevan. | |

*Izvor:* Lindert (2008) u publikaciji Svjetske banke (2009c, str. 21), uz dodatke iz radova Coadyja i drugih (2004a) i Svjetske banke (2009c).

*Dodatak B: Opisi pojedinih zemalja*

*Albanija*

Socijalna pomoć u Albaniji dizajnirana je da pruži novčanu pomoć i usluge socijalnog zbrinjavanja siromašnim, invalidima, djeci bez roditelja i starima. Čine je dva velika ogranka: (1) programi novčanih naknada i (2) usluge socijalnog zbrinjavanja za kvalifikovane kategorije. Programi novčanih naknada obuhvataju program socijalne pomoći koji primjenjuje metodu prihodovnog cenzusa i naziva se *Ndihma Ekonomika* (NE), mjesečne dodatke za sirote i invalide i kompenzacijske transfere za penzionere i njihove porodice.

*Ndihma Ekonomika* se implementira posredstvom lokalnih vlasti. Državna socijalna služba je nadležna za implementaciju politika Ministarstva za rad, socijalna pitanja i jednake mogućnosti (MoLSAEO) i u oblasti socijalne pomoći (NE) i socijalnih usluga. Državna socijalna služba je nadležna i za planiranje i kontrolu korištenja državnih budžetskih sredstava, razvoj standarda usluga i novih usluga, kao i za pripremu dokumenata koje podnosioci molbe treba da popune.

Finansiranje programa *Ndihma Ekonomika* se zasniva na (1) centralnom budžetu i (2) fondovima prikupljenim od jedinica lokalne uprave kroz lokalne poreze i takse. Centralna vlada dodjeljuje individualne blok grantove svakoj jedinici lokalne uprave na osnovi: (1) demografskih karakteristika (podaci o stanovništvu na osnovu građanskih registara), (2) društveno-ekonomskih karakteristika (zaposlenost u javnom sektoru, naknade za nezaposlene u datoj oblasti, penzije, migracije i procjene prosječnih prihoda od zemljoradnje ili stočarstva). Administrativni podaci otkrivaju da je oko 98.800 domaćinstava imalo koristi od *Ndihma Ekonomika* 2012. godine (odnosno oko 15 procenata domaćinstava koja su te godine živjela u Albaniji). Oko 40 procenata tih domaćinstava živjelo je u urbanim područjima a 60 procenata u ruralnim područjima (Državna socijalna služba, 2013.).[15] Potrošnja za *NE* opala je sa 0,84 procenta na manje od 0,28 procenata BDP u 2011. godini.[16]

Maksimalna naknada u okviru NE definisana je kao fiksan iznos i prilagođava se Odlukom Savjeta ministara s ciljem da se dosegne nivo minimalne penzije (ali ne i da ga se nadmaši). Nivo naknade bio je utvrđen na 7.000 leka po porodici 1998. godine (ili oko 50 $) i nije se mijenjao do 2007. Većina naknada iz NE je ispod ovog maksimuma i stoga ne njihov doprinos smanjenju siromaštva kroz donošenje koristi porodicama skroman. 2007. godine, prosječna naknada iz NE za porodice bila je samo 2.600 leka mjesečno, u poređenju sa 4.417 leka mjesečno 2000. godine (Svjetska banka, 2007.)

Istorijski podaci otkrivaju da se obuhvat programa *Ndihma Ekonomika* smanjivao od 2000. do danas, ali uz poboljšanja u ciljanju siromašnijih domaćinstava. Naknadu *Ndihma Ekonomika*, kao naknadu koja se dodjeljuje na osnovu prihodovnog cenzusa, češće nego u drugim programima dobijalju domaćinstva u najsiromašnijim kvintilama. Podaci iz anketa o životnom standardu pokazuju da je najsiromašnija kvintila dobila 44 procenata transfera

[15] http://www.shssh.gov.al/index.php?option=com_content&view=category&layout=blog&id=16&Itemid=8 (pristupljeno 21. aprila 2013.).

[16] http://www.instat.gov.al/al/themes/shëndeti,-sigurimet-shoqërore-dhe-mbrojtja-sociale.aspx (pristupljeno 21. aprila 2013.).

NE. Preciznost ciljanja je bolja u ruralnim područjima, gdje gotovo 46 procenata potrošnje NE dolazi do najsiromašnije kvintile, u odnosu na nekih 39 procenata u urbanim područjima (Svjetska banka, 2007.).

Proces registracije za program *Ndihma Ekonomika* se oslanja na registraciju "po zahtjevu", pri kojoj domaćinstva podnose molbu u kancelariji za socijalnu pomoć odgovarajuće komune ili opštine. Svaki potencijalni korisnik treba da se sastane sa socijalnim administratorom koji provjerava da li zadovoljavaju kriterije kvalifikovanosti. Pored toga, nosilac domaćinstva daje "Izjavu o socijalno-ekonomskom položaju porodice" (Statement of Family Social-Economic Situation - FSES), koju potpisuju svi drugi članovi. Ova molba se podnosi uz više dokumenata koji potvrđuju socio-ekonomski status ili posjed nekretnina. Glavne provjere kod socijalnog administratora obuhvataju sve oblike vlasništva nad kapitalom, druge prihode i naknade koji se primaju, uslove života, status zaposlenosti i prijavljenost u slučaju nezaposlenosti, sadašnje mjesto boravka, vlasništvo nad poljoprivrednom zemljom, prethodne prijevarne radnje radi sticanja koristi od NE itd.

Albanski program novčane socijalne pomoći je relativno mali program koji siromašnim i ugroženim i u urbanim i u ruralnim područjima pruža skromnu pomoć. Iako je ciljanje programa relativno dobro (doseže do znatnog dijela najniže kvintile), neki od glavnih problema na koje se nailazi odnose se na ocjenu dobijenih informacija, s obzirom na nedostatak administrativnih kapaciteta (visok stepen fluktuacije zaposlenih), i na nedostatak resursa (uključujući i teškoće dolaska do udaljenih područja) (Svjetska banka, 2007.). Birokratske prepreke smatraju se još jednom preprekom za ulazak u program. Podnosioci molbe nailaze na teškoće u popunjavanju svih dokumenata i plaćanju za njihovu ovjeru.

*Armenija*

U okviru armenskog sistema socijalne pomoći, porodična naknada za siromaštvo (FPB) je najveći program socijalne pomoći. Pokrenut je 1999. godine, kada je konsolidovano 26 različitih kategorijskih naknada. Cilj FPB je da pomogne krajnje siromašnim porodicama u zemlji. Program koristi indirektni imovinski cenzus za ciljanje transfera porodicama u stanju najveće potrebe. U indikatore korištene za bodovanje spadaju sastav porodice (uzimajući u obzir i ugroženost i zavisnost pojedinih članova porodice), lokacija, kvalitet stambenog prostora i posjedovanje trajnih roba. Neka imovina, kao što je posjedovanje automobila, u praksi funkcioniše kao filter, jer se tako data porodica automatski prepoznaje kao nekvalifikovana. Dio informacija koje je podnio podnosilac molbe tokom procesa podnošenja molbe se provjerava u drugim bazama podataka Vlade. Povrh toga, socijalni radnici posjećuju domaćinstva. Naknade su u osnovi paušalne i sastoje se od fiksnog osnovnog iznosa i dodataka za svako dijete. Korisnici su takođe kvalifikovani za besplatne medicinske usluge. FPB obuhvata oko 12 procenata stanovništva Armenije. 2009. je dosegla 33 procenata najsiromašnije kvintile i 52 procenta najsiromašnijih 10 procenata stanovništva. 43 procenata resursa FPB dobija najsiromašnija decila, a primaoci klasifikovani kao siromašni dobijaju 72 procenata. U poređenju sa 2008. godinom, obuhvat je smanjen ali se poboljšala učinkovitost ciljanja (Svjetska banka, 2011c).

Za razliku od drugih zemalja koje koriste PMT, armenska formula nije empirijski izvedena iz podataka iz ankete s domaćinstvima. Odabrani indikatori i njihovo bodovanje zasnivaju se na kombinaciji mišljenja eksperata i anketi među socijalnim radnicima o karakteristikama siromašnih. Skor je proizvod nekoliko koeficijenata (K u dolje navedenoj formuli). Ako je dati

skor iznad određenog praga, data porodica se kvalifikuje i primaće mjesečnu novčanu pomoć.

Bitno je da prihodi iz zvaničnih izvora ne diskvalifikuju automatski dato domaćinstvo od primanja naknade. Međutim, oni ulaze u formulu.

Formula za bodovanje FPB 2009:

$P = P_{ave} \times K_{fam} \times K_t \times K_{rsd} \times K_{inc} \times K_c \times K_b \times K_{re} \times K_{cst} \times K_e \times K_{ph} \times K_{swa}$,

- P je ukupni broj bodova, koji izražava nivo ugroženosti domaćinstva. Što je ovaj broj viši, ugroženost je veća. Za 2009. godinu, porodice sa brojem bodova 30 i više kvalifikovale su se kvalifikovale za mjesečna primanja iz FPB.
- $P_{ave}$ ije prosječna vrijednost broja bodova socijalne grupe date porodice. Vlada je identifikovala i dodijelila brojčane vrijednosti izvjesnom broju ugroženih socijalnih grupa, među kojima invalidima, djeci, penzionerima i trudnicama. Svaki pojedinac može pripadat i do tri socijalne grupe, pri čemu se najviši broj bodova računa u potpunosti, slijedeći po visini sa 30 procenata vrijednosti, a treći po visini sa 20 procenata vrijednosti. Zatim se na osnovu broja bodova socijalnih grupa svakog pojedinca računa prosjek za domaćinstvo.
- $K_{fam}$ je koeficijent koji se odnosi na broj članova porodice koji nisu sposobni za rad. On se izračunava kao $K_{fam} = 1.00 + 0.02\ m$, pri čemu je *m* broj članova porodice koji su djeca, invalidi prve ili druge kategorije, ili radno sposobni nezaposleni penzioneri.
- $K_t$ koeficijent mjeri nesigurnost u stambenom smislu, zasnovan na geografskom području mjesta stanovanja. Njegova vrijednost može biti 1 (sigurno), 1,03 (nesigurno) ili 1,05 (krajnje nesigurno), a ove vrijednosti se vladinim aktom utvrđuju za svaki grad ili selo.
- $K_{rsd}$ mjeri uslove stanovanja porodice pri čemu se kućama ili stanovima dodjeljuje vrijednost 1, a sve gorim stambenim uslovima dodjeljuju se više vrijednosti (do 1,2 za šatore obezbijeđene nakon zemljotresa).
- $K_{inc}$ je koeficijent prihoda po članu porodice. On se izračunava na osnovu plata i nadnica članova porodice, penzija i naknada za nezaposlenost, kao i vrijednosti stoke (na osnovu fiksne vrijednosti po grlu) i vrijednosti zemlje (obračunate po katastarskoj vrijednosti, sa odbitkom poreza na zemljište). Zatim se izračunava prosjek prihoda po domaćinstvu, a koeficijent se izračunava kao Kinc = 1.2 – 0.000033* (prihod po članu).

Ostali koeficijenti predstavljaju automatske faktore diskvalifikacije (tj. njihova vrijednost može biti 0 ili 1):

- $K_c = 0$ ako domaćinstvo posjeduje motorno vozilo.
- $K_b = 0$ ako je bilo koji član domaćinstva učesnik (dioničar) u firmi ili preduzeću sa ograničenom odgovornošću, ili je dioničar/depozitor u trustu ili zadruzi, ili se bavi zvaničnim preduzetničkim aktivnostima.
- $K_{re} = 0$ if ako bilo koji član porodice kupi nekretninu.
- $K_{cst} = 0$ if ako bilo koji član porodice plaća uvoznu ili izvoznu carinu.
- $K_e = 0$ ako potrošnja električne energije porodice u ljetnim mjesecima nadilazi utvrđeni maksimalni prag.
- $K_{ph} = 0$ ako je iznos prosječnih međugradskih telefonskih računa za bilo koja tri uzastopna mjeseca date godine iznad utvrđenog maksimalnog praga.
- $K_{swa} = 0$ ako socijalni radnik koji obavlja kućnu posjetu ocijeni da data porodica nije kvalifikovana.

*Izvor:* Svjetska banka (2011c, str. 17–18).

*Bugarska*

U Bugarskoj postoje dva osnovna modela budžetskih programa mreža socijalne zaštite u Bugarskoj: model garantovanog minimalnog prihoda (GMI) i model naknade za grijanje (Heating Allowance - HA), koji pokrivaju ugrožena domaćinstva s niskim prihodima. I GMI i HA su programi zasnovani na provjeri prihoda (i imovine). Cilj je da se osigura zaštita najsiromašnijih i najugroženijih pojedinaca i njihovih domaćinstava u podnošenju šokova po prihode i siromaštva (Svjetska banka, 2009b).

Program GMI uveden je 1991. da se osigura novčana naknada za pojedince i domaćinstva koji su ispod određenog nivoa prihoda. Ova naknada teži da popuni jaz između prihoda domaćinstva i praga koji utvrdi Vijeće ministara (obično jednom godišnje) kao cijenu korpe osnovnih prehrambenih proizvoda. Kriteriji kvalifikovanja zasnivaju se na prihodima korisnika i njihovih domaćinstava, imovini, veličini porodica, zdravstvenom i obrazovnom statusu, starosti i drugim uočenim okolnostima. Stvarni mjesečna GMI naknada jednaka je razlici između diferenciranog minimalnog prihoda ili zbira diferenciranih minimalnih prihoda i stvarnih prihoda korisnika u mjesecu koji je prethodio podnošenju molbe za ovu naknadu. GMI naknada se odobrava nakon što podnosilac molbe popuni detaljan upitnik o socijalnom statusu a socijalni radnik provjeri prikupljene informacije.

Naknada za grijanje je takođe naknada koja se dodjeljuje na osnovu prihodovnog cenzusa da se ublaže efekti poskupljenja cijena energenata i grijanja tokom sezone grijanja. Kriteriji kvalifikovanja za naknadu HA slični su naknadi GMI, pri čemu se individualna kvalifikovanost definiše prema diferenciranom minimalnom prihodu za grijanje, koji se množi koeficijentom koji odražava tip domaćinstva, starosnu dob korisnika, njegovu radnu sposobnost i invalidski status, kao i prisustvo djece u kući, njihovu starosnu dob i invalidski status itd.

Bugarska troši oko 1,3 procenata BDP na programe socijalne pomoći, i po tome je ispod prosjeka zemalja OECD (2,5 procenata) i zemalja ECA (1,7 procenata). Ova dva programa, GMI i HA imaju odličan učinak ciljanja, jer 85 procenata naknada GMI ide donjoj kvintili, a 67 procenata resursa programa HA odlazi najsiromašnijim 20 procenata stanovništva. Oba programa obuhvataju manjine, a romska domaćinstva primaju više od tri četvrtine naknada GMI. S druge strane, čini se da GMI i HA naknade imaju relativno visoke administrativne troškove, zbog niza faktora, uključujući tu manje izdašne nivoe naknada, sve izraženije smanjivanje programa i zahtjeve za sprovođenjem prihodovnog cenzusa i verifikacije. Prema tome, program GMI je nešto izvan uobičajenog raspona za administrativne troškove, sa 16 procenata ukupnih troškova, po čemu je najskuplji program koji se sprovodi.

Iako su i naknada GMI i naknada za grijanje efikasni, dobro ciljani programi, njihovi iznosi su skromni - daleko premaleni da bi se zatvorio jaz siromaštva njihovih korisnika. Iznos naknada nije dovoljan da izdigne korisnike iznad praga siromaštva, pa čak ni iznad praga ekstremnog siromaštva.

*Litvanija*

Sistem socijalne zaštite finansiran iz budžeta u Litvaniji sastoji se od dva glavna dijela: kategorijskih naknada i naknada koje se dodjeljuju po osnovu prihodovnog cenzusa (Vizbaraite i Lazutka, 2012.). Cilj programa naknade za socijalnu pomoć (Socialine Pasalpa) je da podrži sve pojedince kojima nedostaju ekonomski resursi ili čiji su resursi

nedovoljni za zadovoljavanje osnovnih potreba. Naknade po osnovu prihodovnog cenzusa obuhvataju naknadu za socijalnu pomoć za siromašne stanovnike, dječju naknadu i socijalnu pomoć učenicima. Naknade kao što su kompenzacija za troškove grijanja i troškove tople i hladne vode takođe se dodjeljuju na osnovu prihodovnog cenzusa.

Naknade za socijalnu pomoć u Litvaniji dodjeljuju se na osnovu Zakona o novčanoj socijalnoj pomoći siromašnim porodicama i samcima, čime se osigurava da se ovakve naknade odobravaju i porodicama i samcima. Jedan od glavnih kriterija kvalifikovanosti za primanje naknada socijalne pomoći za porodice i samce je da su prihodi i vrijednost posjedovane imovine ispod unaprijed definisanog minimalnog praga prihoda (Svjetska banka, 2009f). Izuzeci od obračunavanja prihoda obuhvataju: 1) prihode socijalnog karaktera (paušalne, ciljane naknade za njegu ili brigu (pomoć); 2) troškove za porodice koje imaju invalidnog člana; 3) naknade za troškove prijevoza invalida; 4) dječje naknade; 5) naknade donatorima krvi; 6) novčana pomoć koja se isplaćuje po Zakonu o socijalnim uslugama; 7) socijalne stipendije za studente; 8) prihodi učenika vezani za rad i gotovinske donacije.

Porodice ili pojedinci koji su kvalifikovani za primanje naknade za socijalnu pomoć u Litvaniji obuhvataju zaposlene ili nezaposlene pojedince iz objektivnih razloga kao što su: 1) lica koja pohađaju ustanove opšteg obrazovanja ili druge ustanove formalnog obrazovanja do dobi od 24 godine; 2) lica u dobi za penzionisanje; 3) kad član porodice njeguje drugog člana porodice; 4) kad majka (otac) kod kuće odgaja dijete mlađe od tri godine itd.). Pored ovog, sva nezaposlena lica moraju se registrovati u Birou rada.

Kad je u pitanju učinak ciljanja, oko 66 procenata korisnika socijalne pomoći su ispod linije siromaštva (ovo je jedan od najboljih učinaka ciljanja za bilo koji program socijalne zaštite) a naknade predstavljaju 29 procenata potrošnje siromašnih. Iznos mjesečne naknade je 100 procenata razlike između prihoda koji podržava država (tj. LTL 350) po članu mjesečno i stvarnih prihoda porodice (lica koja žive zajedno) ili samca za prvog člana porodice (kad lica žive zajedno, 80 procenata za drugog člana i 70 procenata za trećeg i sve slijedeće članove.[17]

Neke od glavnih uočenih karakteristika iz litvanskog programa socijalne pomoći su:

- Program socijalne pomoći u Litvaniji je uspješno uveo klizno određivanje visine naknada po skali ekvivalenta odraslog lica. Ovo je korisnije od povećanja naknade za fiksan dio za svakog pojedinog člana, što se viđa u drugim zemljama.
- Jedan od prijedloga u novom Zakonu o izmjenama Zakona o novčanoj socijalnoj pomoći za siromašne porodice i samce (iz januara 2012.) sastoji se u plaćanju dodatnih naknada socijalne pomoći da se podstakne aktiviranje na tržištu rada. Prema tome, kada neki korisnik napusti program socijalne pomoći da bi se zaposlio, on/ona dobijaju dodatnu naknadu socijalne pomoći od 50 procenata prosjeka prethodnih isplata socijalne pomoći. Ovakva naknada važi šest mjeseci uprkos činjenici da porodica možda nije kvalifikovana za socijalnu pomoć.

*Rumunija*

Mreža socijalne pomoći u Rumuniji obuhvata novčane naknade, naknade u naturi kao i socijalne usluge. Gotovinske naknade mreže socijalne pomoći u Rumuniji sadrže pet

[17] http://www.socmin.lt/index.php?1929205838

glavnih stubova: 1) pomoć za djecu i porodicu, 2) pomoć za invalidnost i bolest, 3) komunalije za domaćinstvo, 4) podrška prihodima za krajnju nuždu (garantovani minimalni prihod - Guaranteed Minimum Income/GMI), i 5) naknade "za zasluge" (tj. potpore radnim veteranima, herojima itd.).

Iznos novčanih naknada iz budžeta u Rumuniji je nizak i odražava slab učinak u smanjenju siromaštva. Ovo je i zbog toga što su rashodi na glavne naknade socijalne pomoći po apsolutnoj vrijednosti najniže među zemljama EU. Izvještaj o procjeni siromaštva u 2008. (Svjetska banka, 2008.) naglasio je da ni jedna (budžetska) naknada socijalne pomoći nije dosegla 29 procenata siromašnih u Rumuniji 2007. godine. Oko 60 procenata neobuhvaćenih stanovalo je u ruralnim područjima a 77 procenata u urbanim područjima.

Garantovani program minimalnih prihoda (GMI) je glavni oblik budžetske podrške prihodima i na njega je 2007. godine otpadalo oko 0,1 procenata BDP. Sa aspekta ciljanja, GMI je uspio da usmjeri 45 procenata svojih sredstava ka 10 procenata najsiromašnijih Rumuna (Svjetska banka, 2008.). Mehanizmi ciljanja za GMI su kombinacija između verifikovanog prihodovnog cenzusa (verified means test - VMT) i samo-ciljanja (self-targeting - ST). Iznos porodične naknade je jednak razlici između praga GMI i stvarnih prihoda domaćinstva iz drugih izvora, uključući pripisane prihode od imovine kao što su zemljište i životinje (Svjetska banka, 2008.). Pored toga, prag za socijalnu naknadu izračunava se kao funkcija veličine porodice i uključuje relativno položenu skalu ekvivalentnosti. Zaposleni član pozitivno doprinosi iznosu naknade, jer se ona zbog toga povećava za 15 procenata.

Kontrola mehanizama ciljanja uključuje administrativnu provjeru samoiskazanih prikaza prihoda i verifikaciju imovine kroz posjete stanu domaćinstva. Program obuhvata i kriterijum rada u zajednici, pri čemu se zahtijeva učešće radnosposobnih pojedinaca. Programom upravljaju lokalne vlasti koje ocjenjuju iznos prihoda i druge kriterije kvalifikovanosti kako je to definisalo Ministarstvo rada, porodice i jednakih mogućnosti (MLFEO). Svjetska banka izvještava da je od 2005. standardizovana evaluacija prihoda iz druge imovine i zemljišta (iako je još uvijek obavljaju lokalne vlasti) radi osiguranja horizontalne jednakosti kod metode pripisivanja. S druge strane, sistem se finansira na podnacionalnom nivou tako što se iz Državnog budžeta sva sredstva doznačuju jedinicama lokalne uprave preko oblasnih savjeta.

Kao što je to slučaj u drugim zemljama, npr. u Litvaniji, budžetski program socijalne pomoći u Rumuniji sadrži karakteristiku podsticanja aktivnosti na tržištu rada, tako što se socijalne naknade vezuju za politike aktivacije. Prisustvo zaposlenog člana povećava iznos naknade za 15 procenata, čime se povećava motivacija za učešće na tržištu rada i tako postiže smanjenje zavisnosti od socijalne pomoći.

*Srbija*

Novčana socijalna pomoć (Financial Social Assistance - FSA) ili MoP (*materijalno obezbjeđenje*)/NSP (*novčana socijalna pomoć*) je glavni program socijalne pomoći u Srbiji. Glavni cilj FSA je da se smanji broj lica i domaćinstava ispod minimalnog praga socijalnog statusa koji se određuje administrativno. Program finansira Ministarstvo za rad i socijalnu politiku i cilja sva siromašna lica i domaćinstva čiji je prihod ispod minimalnog praga socijalnog statusa. Svrha socijalnih transfera je da popune jaz između prihoda domaćinstva i navedenog praga, uz prilagođavanje prema veličini domaćinstva.

S unapređenjem Zakona o socijalnoj zaštiti (iz aprila 2011.), obuhvat i nivo naknada FSA su se povećali, posebno za korisnike koji žive u domaćinstvima sa velikim brojem članova i u domaćinstvima u kojima žive članovi koji ne mogu da rade. Pored ovog, aktivacija primalaca u rješavanju njihovog vlastitog problema je sada dio sistema. S novim izmjenama Zakona o socijalnoj zaštiti broj primalaca FSA porastao na tri procenta ukupnog srbijanskog stanovništva.

Prag prihoda određen je u nominalnom iznosu i prilagođava se rastu troškova života (dva puta godišnje, u aprilu i oktobru) na osnovu Zakona o socijalnoj zaštiti. Mjesečna naknada za prihode je oko 61 euro (odnosno 6.774 RSD). Ovaj iznos se prilagođava po ekvivalentu odraslog lica na temelju skale ekvivalentnosti OECD-a.

Pojedinci i njihova domaćinstva moraju zadovoljiti i dodatni kriterij da bi dobili novčanu naknadu za socijalnu pomoć. Kod ocjenjivanja podnesene molbe za FSA, uzimaju se u obzir samo prihoda za posljednja tri mjeseca. Izvori prihoda obuhvataju: 1) zaradu iz zaposlenja, samo-zaposlenja, privremenih ugovora, penzija, invalidnina i drugih transfera iz sfere veteransko/invalidske zaštite, 2) prihode od poljoprivrednih aktivnosti, 3) naknade za nezaposlenost, 4) otpremnina za radnike koji su proglašeni viškom, 5) prihodi od iznajmljivanja imovine, 6) imovinska prava koja podliježu oporezivanju, 7) gotovina i ušteđevina, 8) prihod koji se utvrđuje po mišljenju Centra za socijalni rad i 9) cjeloživotni ugovori o izdržavanju.

Neke kategorije prihoda nisu dio kriterija kvalifikovanosti za FSA, kao na primjer:

1) dječiji dodatak, 2) roditeljski dodatak, 3) starateljski dodatak, 4) prošireni starateljski dodatak, 5) naknada za invalidnost, 6) ad hoc/jednokratna pomoć porodicama u neimaštini, 7) studentske stipendije, 8) otpremnina za odlazak u penziju, 9) nagrade, 10) naknade štete, 11) neuplaćene dionice, 12) naknade koje se plaćaju učesnicima u obukama, razvoju vještina, pripremi za zapošljavanje i sl.

Kriteriji kvalifikovanosti za FSA obuhvataju i cenzus imovine i uslov da se radno sposobno stanovništvo odgovarajuće starosne dobi prijavi u Državnu službu za zapošljavanje (National Employment Service - NES). Sveukupno, kriteriji kvalifikovanosti FSA su vrlo striktni i obuhvataju: 1) prihode ispod 6.774 dinara po ekvivalentu odraslog lica, 2) maksimum jednu sobu po članu porodice, tj. dvije sobe po primaocu starateljske naknade, 3) posjedovanje zemljišta do 0,5 hektara ili 1 hektar za domaćinstva u kojima nisu svi članovi radno sposobni, 4) pokretnu imovinu (automobile, motocikle itd.) sa vrijednošću koja ne prelazi nivo naknade FSA više od šest puta, 5) nikakva imovina ne može biti prodata niti razdijeljena niti nasljedstvo odbijeno i 6) ne mogu postojati nikakvi ugovori o cjeloživotnom izdržavanju.

Kao i u drugim zemljama zapadnog Balkana, program novčane socijalne pomoći u Srbiji je relativno skroman. Udio stanovništva i razmjere obuhvata su niski. Mehanizam ciljanja zasnovan na prihodovnom cenzusu sastoji se od niza administrativnih provjera i terenskih obilazaka. Radi ograničavanja dugoročne zavisnosti od ovog programa, novi Zakon o socijalnoj zaštiti u Srbiji nameće maksimalno trajanje naknade FSA za korisnike koji su radno sposobni (kao i za korisničko domaćinstvo u kom je većina članova radno sposobna). U takvim slučajevima naknada FSA se dobija za do devet mjeseci u toku date kalendarske godine (12 mjeseci). Pretpostavka je da se takva lica mogu zaposliti na sezonskim ili nekim drugim poslovima tokom preostala tri mjeseca. Shodno tome, broj korisnika FSA opada u ljetnim mjesecima.

*Reference*


Ahmed, A. U., & Bouis, H. E. (2002). Weighing what's practical. *FCND Discussion Paper No. 132*.

Alatas, V., Banerjee, A., Hanna, R., Olken, B. A., & Tobias, J. (2010). Targeting the poor: Evidence from a field experiment in Indonesia, *NBER Working Paper 15980*.

Atkinson, A. B. (1995). On Targeting Social Security: Theory and Western Experience with Family Benefits. In *Public Spending and the Poor*. London and Baltimore: John Hopkins University Press.

AusAID. (2011). *Targeting the Poorest: An assessment of the proxy means test methodology*. Canberra: AusAID.

Azevedo, V., & Robles, M. (2010). Multidimensional Targeting: Identifying Beneficiaries of Conditional Cash Transfer Programs. *OPHI Research in progress paper*, *20*.

CASE. (2005). *Case study summary: Kyrgyz Republic Unified Monthly Benefit Program* (Case study prepared for the World Bank regional study "Program Implementation Matters for Targeting Performance: Evidence and Lessons from the ECA Region"). Washington, DC: World Bank.

Castañeda, T. (2005). Targeting Social Spending To The Poor With Proxy-Means Testing: Colombia's SISBEN System. *Social Protection Discussion Paper*, *No. 529*.

Castañeda, T., & Lindert, K. (2005). Designing and Implementing Household Targeting Systems: Lessons from Latin America and The United States. *Social Protection Discussion Paper Series*, *No. 526*.

Coady, D., Grosh, M., & Hoddinott, J. (2004a). *Targeting Transfers in Developing Countries: Review of Lessons and Experience*. Washington, DC: World Bank.

Coady, D., Grosh, M., & Hoddinott, J. (2004b). Targeting Outcomes Redux. *World Bank Research Observer*, *19*(1), 61–85.

Coady, D., & Skoufias, E. (2001). On the targeting and redistributive efficiencies of alternative transfer instruments. *FCND Discussion Paper*, *No. 100*.

De Janvry, A., Finan, F., Sadoulet, E., Nelson, D., Lindert, K., De la Brière, B., & Lanjouw, P. (2005). Brazil's Bolsa Escola Program: The Role of Local Governance in Decentralized Implementation. *Social Safety Nets Primer Series*.

De Neubourg, C., Castonguay, J., & Roelen, K. (2007). Social safety nets and targeted social assistance: Lessons from the European experience. *Social Protection Discussion Paper*, *No. 718*. Retrieved from http://www-wds.worldbank.org/servlet/WDSContentServer/WDSP/IB/2007/11/20/000020953_20071120120538/Rendered/PDF/415290Safety0nets0SP0071801PUBLIC1.pdf

Gassmann, F. (2010). *Note on Performance Measurement for Social Protection* (Note commissioned by DG EuropeAid, E3/ESIP). European Commission.

Gassmann, F. (2011a). Protecting Vulnerable Families in Central Asia: Poverty, vulnerability and the impact of the economic crisis. *UNU-MERIT Working Paper Series*, *#2011-042*.

Gassmann, F. (2011b). TO WHAT EXTENT DOES THE EXISTING SAFETY NET PROTECT THE POOR?

Gelbach, J. B., & Pritchett, L. (2002). Is More for the Poor Less for the Poor? The Politics of Means-Tested Targeting. *The B.E. Journal of Economic Analysis & Policy*, *topics.2*(1).

Gomart, E. (1998). *The Poorest of the Poor in Armenia*. Washington, DC: World Bank.

Grosh, M. (1994). *Administering targeted social programs in Latin America: From platitudes*

*to practice*. Washington, DC: World Bank.

Grosh, M., & Baker, J. (1995). *Proxy Means Tests for Targeting Social Programs* (Living Standard Measurement Study No. 118). Washington, DC: World Bank.

Grosh, M., Del Ninno, C., Tesliuc, E., & Ouerghi, A. (2008). *For Protection and Promotion. The Design and Implementation of Effective Safety Nets*. Washington, DC: World Bank.

Grosh, M., & Tesliuc, E. (2005). Program Implementation Matters for Targeting Performance: Evidence and Lessons from the ECA Region. Presented at the Bucharest seminar, Bucharest.

Harutyunyan, L. (2005). *Case Study Summary: Armenia Family Poverty Benefit* (Case study prepared for the World Bank regional study "Program Implementation Matters for Targeting Performance: Evidence and Lessons from the ECA Region"). Washington, DC: World Bank.

Haughton, J., & Khandker, S. R. (2009). *Handbook on Poverty + Inequality*. Washington, DC: World Bank.

IMF. (2012). *World Economic Outlook Database (October 2012)*. Washington, DC: IMF.

Kolpeja, V. (2005). *Case study summary: Albania's Ndihme Ekonomika* (Case study prepared for the World Bank regional study "Program Implementation Matters for Targeting Performance: Evidence and Lessons from the ECA Region"). Washington, DC: World Bank.

Lindert, K. (2008). *Jobs for Brazil's Poor: Social Protection Programs and Labor Supply Impacts on the Poor in Brazil*. Washington, DC: World Bank.

Narayan, A., & Yoshida, N. (2005). *Proxy Means Tests for Targeting Welfare Benefits in Sri Lanka*. Retrieved from http://www-wds.worldbank.org/external/default/WDSContentServer/IW3P/IB/2005/08/09/000090341_20050809094744/Rendered/PDF/332580PAPER0SASPR17.pdf

OPM. (2012). *Kazakhstan: External Evaluation of BOTA Programmes, Vol. III: Targeting Analysis*. Oxford: Oxford Policy Management.

Ruggeri Laderchi, C., Saith, R., & Stewart, F. (2003). Does it matter that we don't agree on the definition of poverty? A comparison of four approaches. *QEH Working Paper Series Number 107*.

Samson, M., Van Niekerk, I., & Mac Quene, K. (2010). *Designing and implementing social transfer programmes* (2nd ed.). Cape Town: Economic Policy Research Institute.

Sen, A. (1995). The political economy of targeting. In *Spending and the Poor* (pp. 11–24). Baltimore and London: John Hopkins University Press.

Slater, R., Farrington, J., Vigneri, M., Samson, M., & Akter, S. (2009). Targeting of Social Transfers: A review for DFID. *London: ODI*.

Tesliuc, E. (2004). Mitigating Social Risks in Kyrgyz Republic. *Social Protection Discussion Paper*, *No. 408*.

UNICEF. (2010). *Survey of Barriers to Access to Social Services Georgia 2010. Why not all poor families get social benefits and services* (Survey Report). Tbilis: UNICEF.

United Nations. (2005). *Designing Household Survey Samples: Practical Guidelines*. New York: United Nations.

Vizbaraité, V., & Lazutka, R. (2012). *Lithuania. Improving the efficiency of social protection*.

Weigand, C., & Grosh, M. (2008). Levels and Patterns of Safety Net Spending in Developing and Transition Countries. *Social Protection Discussion Paper*, *No. 817*.

Williams, P., Larrison, J., Strokova, V., & Lindert, K. (2012). Social Safety Nets in Europea and Central Asia: Preparing for Crisis, Adapting to Demographic Change, and Promoting Employability. *ECA Knowledge Brief*, *Volume 48*.

World Bank. (1999). *Improving Social Assistance in Armenia*. Washington, DC: World Bank.

World Bank. (2002). *Protecting People with Social Safety Nets*. Washington, DC: World Bank.

World Bank. (2007). *Albania: Urban Growth, Migration and Poverty Reduction. A Poverty Assessment.* Washington, DC: World Bank.

World Bank. (2008). *Romania. Poverty Monitoring Analytical and Advisory Assistance Program Are the Most Vulnerable Protected?* Washington, DC: World Bank.

World Bank. (2009a). *Targeting Performance and Poverty Impact of Social Benefits in Kazakhstan: Evidence from the 2007 Household Budget Survey*. Note prepared by the World Bank as part of FY09 JERP TA activity, mimeo.

World Bank. (2009b). *Bulgaria - Social Assistance Programs: Cost, Coverage, Targeting and Poverty Impact*. Washington, DC: World Bank. Retrieved from https://openknowledge.worldbank.org/handle/10986/3187

World Bank. (2009c). *Social Assistance Transfers in Bosnia and Herzegovina. Moving Toward a More Sustainable and Better-Targeted Safety Net* (Policy Note No. AAA33-BA). Washington, DC: World Bank.

World Bank. (2009d). *Social Safety Net in the Kyrgyz Republic. Capitalizing on Achievements and Addressing New Challenges*. Washington, DC: World Bank.

World Bank. (2009e). *Georgia Poverty Assessment*. Washington, DC: World Bank.

World Bank. (2009f). *Lithuania. Social Sectors Public Expenditure Review Prepared for the Republic of Lithuania by the World Bank Group*. Washington, DC: World Bank.

World Bank. (2010a). *Turmoil at Twenty: Recession, Recovery, and Reform in Central and Eastern Europe and the Former Soviet Union*. Washington, DC: World Bank.

World Bank. (2010b). *Project Appraisal Document*. Washington, DC: World Bank.

World Bank. (2011a). *Social Safety nets in the Western Balkans. Design, Implementation, and Performance*. Washington, DC: World Bank.

World Bank. (2011b). *Republic of Tajikistan. Delivering Social Assistance to the Poorest Households*. Washington, DC: World Bank.

World Bank. (2011c). *Armenia. Social Assistance Programs and Work Disincentives*. Washington, DC: World Bank.

World Bank. (2012a). Glossary. *Safety nets and transfers*. Retrieved from http://go.worldbank.org/VE0A54UI20

World Bank. (2012b). *Tajikistan: Evaluation of the Pilot of Poverty-Targeted Social Assistance in Yevon and Istaravshan Districts (preliminary report)*. Washington, DC, mimeo: World Bank.

World Bank. (2012c). Targeting Works! Lessons from the Europe & Central Asia Region. Retrieved November 29, 2012, from http://go.worldbank.org/1PHXYORMZ0

Zalimiene, L. (2005). *Case Study Summary: Lithuania's Social Benefit Program* (Case study prepared for the World Bank regional study "Program Implementation Matters for Targeting Performance: Evidence and Lessons from the ECA Region"). Washington, DC: World Bank.