

Indeks višestruke deprivacije

Konceptualni okvir za utvrđivanje općina i gradova u
Hrvatskoj koji zaostaju u razvoju

Ožujak 2017.
Projekt sufinancira Europska unija iz Europskog fonda za regionalni razvoj

Sadržaj

Indeks višestruke deprivacije.....	0
1. Osnovne informacije.....	2
2. Cilj.....	3
3. Trenutačni indeksi deprivacije u Hrvatskoj.....	4
4. Europsko iskustvo s mjerenjem višedimenzionalne deprivacije.....	7
5. Prijedlog revidiranog indeksa višestruke deprivacije za Hrvatsku.....	13
6. Metodologija izračuna IVD-a.....	17
Ključni koncepti	17
Dostupnost podataka i odabir pokazatelja	20
Standardizacija	22
Utvrđivanje i agregiranje.....	25
Ponderiranje pokazatelja	27
Vremenska usporedba i upotreba fiksnih percentilnih rangova.....	29
7. Primjena IVD-a za utvrđivanje, ocjenjivanje i praćenje provedbe intervencija u depriviranim regijama.....	30
8. Završne napomene	36
Prilog 1. Aplikacije.....	37
Literatura	41
Prilog 1. Opis pokazatelja koji se koriste za izračun IVD-a	42
Domena: Ekonomska.....	42
Poddomena Tržište rada.....	42
Poddomena Fiskalni kapacitet	43
Poddomena Gospodarski razvoj	43
Domena: Socijalna.....	44

Poddomena Socijalna zaštita	44
Poddomena Zdravstvo i obrazovanje.....	45
Poddomena Demografija.....	45
Domena: Pristup uslugama	46
Poddomena Socijalne usluge.....	46
Poddomena Fizička infrastruktura	47

1. Osnovne informacije

Kao država članica EU-a, Hrvatska je dio strategije Europa 2020. te, u skladu s tim, nastoji smanjiti broj osoba koje žive u riziku od siromaštva ili socijalne isključenosti. Postizanje tog cilja ovisi o izradi odgovarajućih politika i programa te učinkovitog mehanizma njihova usmjeravanja za što je potrebno dobro poznavati razlike u životnim standardima u Hrvatskoj. Hrvatska je zainteresirana za osmišljavanje politika i programa za smanjenje regionalnih razlika unutar svojih granica. Na primjer, u Strategiji borbe protiv siromaštva i socijalne isključenosti (2014. – 2020.) regionalni pristup posebno se navodi kao dio strategije smanjenja siromaštva i socijalne isključenosti.

U Strategiji borbe protiv siromaštva i socijalne isključenosti u Republici Hrvatskoj za razdoblje 2014. – 2020. ispituju se skupine stanovništva koje su i dalje izložene siromaštvu, socijalnoj isključenosti i različitim oblicima materijalne deprivacije koji dovode do diskriminacije. Te skupine uključuju starije osobe, jednočlana kućanstva, jednoroditeljske obitelji, obitelji s više od dvoje djece, djecu bez odgovarajuće roditeljske skrbi, osobe s nižim stupnjevima obrazovanja, osobe s invaliditetom, hrvatske branitelje, stradalnike ratnih zbivanja i članove njihovih obitelji, povratnike, raseljene osobe i etničke manjine (uglavnom Rome i Srbe).

Siromaštvo u Hrvatskoj ima snažnu teritorijalnu dimenziju. Uključivanjem teritorijalne dimenzije u politiku mogu se ostvariti bolji rezultati. Čimbenici koji utječu na udio osoba u riziku od siromaštva prostorno su najviše koncentrirani u malim gradovima i naseljima na istoku i jugoistoku zemlje, uglavnom uz granicu s Bosnom i Hercegovinom te Srbijom. To su i područja koja su najviše bila zahvaćena Domovinskim ratom 1990-ih.

Ministarstvo regionalnoga razvoja i fondova Europske unije (MRRFEU), Ministarstvo za demografiju, obitelj, mlade i socijalnu politiku (MDOMSP), Državni zavod za statistiku (DZS) i druga državna tijela nastoje dobiti detaljnije i potpunije dokaze o prostornoj distribuciji siromaštva i socijalne isključenosti te dostupnim resursima za borbu protiv njih. Te će dokaze Vlada Republike Hrvatske zatim koristiti kao osnovu za informirano osmišljavanje politika i raspodjelu sredstava iz proračuna te fondova EU-a u cilju promicanja uključenosti i regionalnog razvoja, posebno u depriviranim područjima.

Kao pomoć u postizanju tog cilja, u okviru projekta MRRFEU-a i Svjetske banke koji uključuje savjetodavne usluge uz naknadu u području prostorne analize siromaštva i socijalne isključenosti jedna od aktivnosti odnosi se na izradu detaljne georeferencirane baze podataka koja pruža informacije o

prostornoj distribuciji socijalne isključenosti korištenjem niza pokazatelja blagostanja, deprivacije te distribucije socijalnih usluga i infrastrukture kao osnove za daljnje djelovanje.

2. Cilj

U prosincu 2014. Europska komisija usvojila je Operativni program (OP) „Konkurentnost i kohezija 2014. – 2020.” za Hrvatsku.¹ Taj OP ima devet tematskih ciljeva s investicijskim prioritetima, specifičnim ciljevima i povezanim alokacijama financijskih sredstava. Očekivani rezultat u okviru specifičnog cilja 9b1 – Održiva fizička, socijalna i gospodarska regeneracija pet depriviranih pilot područja – poboljšanje je socioekonomskih i životnih uvjeta za osobe koje žive u pilot-područjima s od 10 000 do 35 000 stanovnika, čime će se zaustaviti ili obrnuti gubitak stanovništva.² U odabranim pilot-područjima posebna će se pažnja usmjeriti na potrebe marginaliziranih i ranjivih zajednica koje žive u njima. Ta će se integrirana regeneracija uključiti u budući pristup koji će Hrvatska primjenjivati u području održivog razvoja povezanog sa smanjenjem siromaštva i povećanjem socijalne uključenosti.

Razvoj integriranog pristupa regeneraciji prema područjima planira se s pomoću triju mehanizama: i. pet pilot-projekata koji se neovisno provode i službeno ocjenjuju; ii. prikupljanja poboljšanih podataka za mala područja i izrade povezanih karata siromaštva te uspostavljanja odgovarajućih sustava upravljanja i kontrole te iii. povećanja institucionalnih kapaciteta ključnih dionika i osoblja. Intervencije koje se poduzimaju u pilot-područjima planiraju se provesti i u drugim područjima.

Iz Europskog fonda za regionalni razvoj (ERDF), izvora financiranja OP-a Konkurentnost i kohezija 2014. – 2020., izdvojeno je oko 100 milijuna EUR za pružanje potpore fizičkoj, gospodarskoj i socijalnoj regeneraciji depriviranih zajednica u urbanim i ruralnim područjima. Uz to, cilj je OP-a promicati jednake mogućnosti, aktivno sudjelovanje i bolju zapošljivost. To bi, u okviru ERDF-a, uključivalo izgradnju ili sanaciju infrastrukture i stambenih jedinica uz pružanje potpore poduzećima.

Uz to, u okviru Europskog socijalnog fonda (ESF), izvora financiranja OP-a Učinkoviti ljudski potencijali 2014. – 2020., podržanim pokazateljima *outputa* nastoji se povećati sudjelovanje dugotrajno

¹ Operativni program Konkurentnost i kohezija 2014. – 2020., www.strukturnifondovi.hr

² U skladu sa Zakonom o lokalnoj i područnoj (regionalnoj) samoupravi malim gradovima smatraju se gradovi s manje od 35.000 stanovnika. Prema podacima iz popisa stanovništva 2011. u Hrvatskoj postoji 50 malih gradova koji imaju od 10.000 do 35.000 stanovnika i osam gradova srednje veličine koji imaju od 35.000 do 50.000 stanovnika. Samo se devet gradova može smatrati velikim gradovima, uključujući četiri grada s više od 100.000 stanovnika. Postoji i 60 jako malih gradova s manje od 10.000 stanovnika.

nezaposlenih osoba, kao i Roma i drugih pripadnika manjina u programima aktivnog tržišta rada. Dodatne aktivnosti predviđene su u okviru specifičnog cilja 9i2 OP-a Učinkoviti ljudski potencijali „Jačanje aktivnog uključivanja kroz implementaciju integriranih projekata za obnovu 5 nerazvijenih pilot-područja”, uz okvirnu alokaciju od 20 milijuna EUR. Te će se aktivnosti koristiti za sufinanciranje pružanja usluga povezanih sa socijalnim pitanjima, obrazovanjem, gospodarstvom i zapošljavanjem kao što su integrirani projekti u kojima se mogu kombinirati različite mjere zapošljivosti, kao što su individualna podrška, savjetovanje, usmjeravanje, pristup općem i strukovnom obrazovanju i osposobljavanju, samozapošljavanje, društveno poduzetništvo te pristup socijalnim i zdravstvenim uslugama.

Pokazatelj rezultata koji je specifičan za program (specifični cilj ERDF-a 9b1)³ odnosi se na smanjenje pada broja stanovnika u pet pilot-područja obuhvaćenih programom socijalne, gospodarske i teritorijalne regeneracije (mjereno vitalnim indeksom).

Podaci za mala područja koji služe kao potpora utvrđivanju ciljnih područja, kao i razvoju integriranih politika i programa za deprivirane urbane i ruralne zajednice dostupni su u ograničenoj mjeri. MRRFEU je predložio izradu indeksa višestruke deprivacije (IVD). Iako je MRRFEU već izračunao IVD⁴, od Svjetske banke zatražio je potporu u daljnjem razvoju indeksa.

3. Trenutačni indeksi deprivacije u Hrvatskoj

IVD se temelji na primjeni nekoliko različitih dimenzija deprivacije koje se mogu zasebno mjeriti. Višestruka deprivacija često se definira kao situacija u kojoj se odražavaju niže razine životnog standarda i koja može proizaći iz nekoliko nemonetarnih pokazatelja. Akademski zajednica i praktičari odavno su prihvatili da je siromaštvo po svojoj prirodi višedimenzionalno. Siromaštvo ne znači samo manjak novčanih sredstava. Osobe s jednakim dohotkom mogu biti izložene različitim deprivacijama; na primjer, lošijem životnom standardu zbog učinaka akumuliranih resursa, radnog statusa, razine obrazovanja, zdravstvenog stanja, stanarskog prava, nenovčanih prihoda i socijalnih naknada.

DZS. Državni zavod za statistiku svake godine objavljuje pokazatelje *materijalne deprivacije*, zajedno sa stopom materijalne deprivacije koja predstavlja postotak osoba koje žive u kućanstvima koja si (izričito zbog nedostatka financijskih sredstava) ne mogu priuštiti najmanje tri od sedam stavki deprivacije.⁵

³ Pokazatelj se mjeri vitalnim indeksom stanovništva kako bi se pokazao potencijal rasta stanovništva izražen kao broj živorođenih na 100 umrlih. Ciljna vrijednost za pet pilot-područja određena je na 67,00.

⁴ Postojeći IVD MRRFEU-a detaljno se razmatra kasnije u tekstu.

⁵ www.dzs.hr

Anketa EU-SILC koja je reprezentativna na nacionalnoj razini koristi se kao izvor podataka za dobivanje informacija o materijalnoj deprivaciji. Nacionalna stopa materijalne deprivacije u 2016. iznosila je 30,1 %. Taj je pokazatelj jednak pokazatelju koji EUROSTAT⁶ objavljuje za cijeli EU.

MRRFEU.⁷ *Indeks razvijenosti*, koji je izradio MRRFEU, koristi se za određivanje jedinica lokalne samouprave (županija, gradova i općina) u Hrvatskoj koje zaostaju i na koje se primjenjuju izuzeća od oporezivanja obuhvaćena zakonima o porezu na dohodak i porezu na dobit. Uz to, taj se indeks koristi i za ocjenu razvoja lokalnih i regionalnih autonomnih područja. Indeks se izračunava kao funkcija pet pokazatelja te se koriste sljedeći ponderi:

- a. stopa nezaposlenosti – 30 %;
- b. dohodak (oporezivi prihod fizičkih poreznih obveznika) po stanovniku – 25 %;
- c. proračunski prihodi jedinica lokalne samouprave po stanovniku – 15 %;
- d. kretanje stanovništva – 15 %;
- e. udio građana sa srednjoškolskim i višim obrazovanjem u radno sposobnom stanovništvu – 15 %.

U skladu s Odlukom o indeksu razvijenosti ti se pokazatelji izračunavaju kao trogodišnji prosjek kako bi se izbjegle fluktuacije. Podaci se standardiziraju za cijelu distribuciju. Postupak standardizacije prethodnih pokazatelja provodi se na temelju sljedeće formule:

$$X_{i \text{ stand.}} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}$$

pri čemu je x vrijednost pokazatelja za svaku jedinicu lokalne samouprave, dok su $x_{\min}$ i $x_{\max}$ minimalna odnosno maksimalna vrijednost pokazatelja na razini jedinica lokalne samouprave. Indeks se izračunava kao ponderirani prosjek odstupanja standardiziranih vrijednosti svakog pokazatelja od nacionalnog prosjeka.

Postojeći *indeks višestruke deprivacije*⁸ za sve jedinice lokalne samouprave, kako ga je zamislio MRRFEU, ponderirana je agregirana vrijednost specifičnih pokazatelja siromaštva i socijalne isključenosti, raspodijeljenih u niz domena (kao što su demografija, socijalna pitanja, obrazovanje, gospodarstvo i područja zahvaćena ratom). Domene (i pokazatelji) mogu se na karti prikazati odvojeno ili zajedno u obliku karte višestruke deprivacije. Indeks višestruke deprivacije koji se privremeno koristi temelji se

⁶ EUROSTAT-ov pokazatelj višestruke deprivacije opisan je kasnije u ovom izvješću.

⁷ Prikazane su samo dvije mjere za regije koje zaostaju, ali postoje i druge

⁸ To nije službeni postupak i ne bi se smio zamijeniti s indeksom koji je predložen u ovom izvješću.

na postojećim agregiranim podacima koji su prikupljeni u okviru popisa stanovništva i javnih administrativnih registara. Metodologija uključuje pokazatelje za izračun vrijednosti indeksa višestruke deprivacije i udjela pojedinog pokazatelja u izračunu indeksa, izvore podataka i metodu izračuna indeksa višestruke deprivacije. Vrijednost indeksa izračunava se kao ponderirano prosječno odstupanje standardizirane vrijednosti pokazatelja od hrvatskog prosjeka. Indeks višestruke deprivacije korišten je kao jedan od kriterija za odabir pet pilot-područja za implementaciju integrirane fizičke, gospodarske i socijalne regeneracije malih gradova u ratom zahvaćenim područjima.

Tablica 1.: Indeks višestruke deprivacije i udio pokazatelja u izračunu indeksa

Domena / Pokazatelj	Ponder
Stanje stanovništva	20 %
a) Kretanje stanovništva	15 %
b) Indeks starosti stanovništva	5 %
Socijalno stanje	35 %
a) Stopa nezaposlenosti	15 %
b) Stope aktivnosti stanovništva	10 %
c) Udio korisnika socijalne pomoći	10 %
Obrazovni status	10 %
a) Udio osoba s visokoškolskim obrazovanjem u radno sposobnom stanovništvu	10 %
Ekonomska snaga i potencijal jedinice lokalne samouprave	20 %
a) Osobni dohodak po stanovniku	10 %
b) Proračunski prihodi jedinica lokalne samouprave po stanovniku	10 %
Gustoća stanovništva	5 %
Koeficijent za područja zahvaćena ratom	10 %

Izvor: MRRFEU.

U okviru tehničke pomoći cilj je MRRFEU-a ojačati indeks višestruke deprivacije radi daljnje implementacije kroz:

- utvrđivanje odgovarajućeg i proširenog skupa pokazatelja za koje su dostupni podaci za mala područja;
- sporazum o nizu relevantnih domena;
- metodološku robusnost indeksa višestruke deprivacije, uključujući ponderiranje različitih pokazatelja i domena;
- mapiranje tih podataka s pomoću GIS-a na razini općine kako bi se dobile interaktivne karte Hrvatske;
- osposobljavanje službenika Ministarstva u području ažuriranja i poboljšanja karata u okviru sustava GIS.

4. Europsko iskustvo s mjerenjem višedimenzionalne deprivacije

Nekoliko europskih zemalja (posebno Njemačka i Ujedinjena Kraljevina) razvilo je indekse višestruke deprivacije (IVD-ove). Štoviše, Eurostat se uključio u opisivanje iskustava u izradi IVD-ova u EU-u, kao i u izračun takvih pokazatelja za države članice EU-a.

U globalnom kontekstu, UNDP i Oksfordska inicijativa za siromaštvo i razvoj (OPHI) izradili su višedimenzionalni indeks siromaštva (MPI) koji obuhvaća više od 100 zemalja u razvoju. U MPI-ju se siromaštvo promatra na individualnoj razini te se on temelji na podacima iz ankete o kućanstvima. Ako je neka osoba deprivirana prema tri ili više pokazatelja od njih deset (primjenjuje se postupak ponderiranja), prema indeksu je se smatra siromašnom te se intenzitet njezina siromaštva mjeri brojem deprivacija kojima je ona izložena. Za izračun indeksa koriste se tri dimenzije (zdravstvo, obrazovanje i životni standard) i deset pokazatelja (smrtnost djece, prehrana, godine školovanja, pohađanje škole, gorivo za kuhanje, zahod, voda, električna energija, podni materijal i imovina).

Eurostat. Eurostat je uključen u izradu pokazatelja materijalne deprivacije za države članice EU-a. Materijalna deprivacija smatra se stanjem ekonomskog napora i nedostatkom trajnih dobara u kućanstvu. Odnosi se na „nemogućnost nabave određenih dobara koja većina ljudi smatra poželjnim ili čak potrebnim za vođenje zadovoljavajućeg života”. Pokazateljima materijalne deprivacije mjeri se udio stanovništva koje si ne može priuštiti između tri i četiri sljedeće stavke: i. plaćanje stanarine, stambenog kredita ili računa za režije; ii. mogućnost adekvatnog grijanja u vlastitom domu; iii. mogućnost podmirivanja neočekivanih izdataka; iv. redoviti obrok koji sadrži meso ili proteine; v. odlazak na godišnji odmor; vi. televizor; vii. perilicu za rublje; viii. automobil; ix. telefon. Osobe koje žive u kućanstvima koja si ne mogu priuštiti najmanje tri od tih devet stavki smatraju se materijalno depriviranim, dok se za osobe koje žive u kućanstvima koja si ne mogu priuštiti najmanje četiri stavke smatra da se nalaze u teškoj materijalnoj deprivaciji.

Stope materijalne deprivacije i teške materijalne deprivacije izračunavaju se kao udio stanovništva koje ne može platiti najmanje tri odnosno četiri od devet stavki. Pokazatelji se dobivaju iz skupova podataka za EU-SILC te su dostupni i na razini NUTS1 ili NUTS2, ovisno o pojedinoj zemlji. Važno je napomenuti da su ti pokazatelji usmjereni na aspekte materijalnih uvjeta života te da ne obuhvaćaju ostale dimenzije deprivacije kao što je zdravstvo, zapošljavanje, obrazovanje ili socijalno sudjelovanje, niti su izravno povezani s politikama.

U širem okviru pokazatelja materijalne deprivacije Eurostat dodatno izračunava pokazatelj deprivacije s obzirom na uvjete stanovanja i pokazatelj s obzirom na okruženje u kojem se stan nalazi. Pokazatelj deprivacije s obzirom na uvjete stanovanja definira se kao postotak stanovništva koji živi u stambenom prostoru koji obilježava sljedeće: i. prokišnjavanje krova, stan je vlažan, dotrajala i trula stolarija ili podovi; ii. stan nema kupaonicu s kadom ili tušem; iii. nema zahoda unutar stana koji koristi samo kućanstvo; i iv. dodatni problemi sa stanom (npr. stan je premračan, nema dovoljnu količinu svjetla). Udjeli se izračunavaju za deprivaciju u nula, jednoj, dvije, tri ili sve četiri dimenzije. Zaseban pokazatelj materijalne deprivacije s obzirom na okruženje u kojem se stan nalazi odnosi se na udio stanovništva koje je prijavilo probleme s bukom. Ti dodatni pokazatelji ne kombiniraju se s izvornim popisom devet stavki materijalne deprivacije.⁹

Ujedinjena Kraljevina. Ujedinjena Kraljevina najviše je napredovala u razvoju indeksa višestruke deprivacije za mala područja. Zasebni indeksi razvijeni su i izrađeni za svaku od četiri države Ujedinjene Kraljevine (Englesku, Wales, Sjevernu Irsku i Škotsku). Ti indeksi za pojedine države imaju isti koncept i opću metodologiju. Međutim, postoje razlike u domenama, pokazateljima, obuhvaćenim područjima i vremenu koji su korišteni pri njihovoj izradi. Za indekse su „odgovorne” vlade tih država. U skladu s tim, metodologija njihove izrade, rezultati i pojašnjenja objavljuju se na mrežnim stranicama tih vlada.¹⁰ Ti su indeksi usmjereni na utvrđivanje područja najveće deprivacije. No, kao što je istaknulo Ministarstvo za zajednice i lokalnu upravu (eng. *Department for Communities and Local Government*), lokalni kreatori politika i zajednice također ih mogu koristiti za učinkovito usmjeravanje resursa.

Iz pregleda indeksa deprivacije za Englesku u 2015. vidljivo je dobro razvijeno iskustvo u operacionalizaciji mjerenja višestruke deprivacije u EU-u.¹¹ Indeksi deprivacije za Englesku iz 2015. peto su izdanje tih mjerenja. Deprivacija je prikazana skupom zavisnih mjera na razini malih područja. Mala područja ili četvrti oblikovane su tako da imaju sličan broj stanovnika, s prosjekom od oko 1.500 osoba ili 650 kućanstava. Ured za nacionalnu statistiku utvrdio je ta područja za potrebe statističkog

⁹ Za razmatranja o pokazateljima materijalne deprivacije u kontekstu EU-a vidjeti, na primjer, Fusco, Guio i Marlier (2013.) te Guio (2009.). Fusco, Guio i Marlier (2013.; str. 46.) primjećuju da se „intuitivnom privlačnošću tih mjera može objasniti njihova popularnost, ali se time ne daju dostatne smjernice za njihovu praktičnu primjenu, bez obzira na to je li riječ o statističkoj analizi ili kreiranju politika”.

¹⁰ Informacije o indeksima deprivacije za Englesku iz 2015., <https://www.gov.uk/government/statistics/english-indices-of-deprivation-2015>; Indeks višestruke deprivacije za Škotsku iz 2012., <http://www.gov.scot/Topics/Statistics/SIMD>; Indeks višestruke deprivacije za Wales iz 2014., <http://gov.wales/statistics-and-research/welsh-index-multiple-deprivation/?lang=en>; Indeks višestruke deprivacije za Sjevernu Irsku iz 2010. http://www.nisra.gov.uk/deprivation/nimdm_2010.htm.

¹¹ Indeksima deprivacije za 2015. skupno se upućuje na indeks višestruke deprivacije za 2015., indekse domena, dopunske indekse i geografske preglede većih područja.

izvješćivanja za mala područja. U Engleskoj je 2015. bilo 32.844 takvih područja. Indeksi se temelje na sedam domena deprivacije:

- deprivaciji s obzirom na dohodak;
- deprivaciji s obzirom na zapošljavanje;
- deprivaciji s obzirom na obrazovanje, vještine i osposobljavanje;
- deprivaciji s obzirom na zdravlje i invaliditet;
- kriminalitetu;
- preprekama stanovanju i uslugama;
- deprivaciji s obzirom na životno okruženje.

Svaka je domena dodatno razrađena kroz niz pokazatelja. Popis pokazatelja prikazan je u tablici 2. Pokazatelji se odnose na najnovije podatke. Kad je riječ o verziji iz 2015., većina pokazatelja obuhvaća podatke za fiskalnu godinu 2012./2013. Za neke se pokazatelje koriste podaci za dvije ili tri godine kako bi se smanjio problem malih brojeva ili fluktuacija između godina. U nekim je slučajevima primijenjen postupak skupljanja (eng. *shrinkage*). Skupljanje je mehanizam procjene pokazatelja korištenjem ponderirane kombinacije podataka iz određenog malog područja i podataka iz područja na višoj razini.

Pokazatelji unutar svake domene standardizirani su prema svojem rangu na ljestvici i pretvoreni u normalnu distribuciju prije nego što su objedinjeni u rezultat domene korištenjem pondera određenih faktorskom analizom. Blaga varijacija prethodno navedenog postupka agregiranja primjenjuje se za neke od domena ili poddomena.

Indeks višestruke deprivacije, odnosno zbirna mjera deprivacije, objedinjuje rezultate sedam domena primjenom fiksnih pondera (tablica 2.). Unutar tri domene postoji šest poddomena te se i za njih određuju rezultati. Svaki indeks objavljuje se u obliku ranga (pri čemu je 1 oznaka područja najveće deprivacije) i pokazatelja decila (pri čemu 1 znači da se jedinica nalazi među 10 % jedinica s najvećom deprivacijom). Uz indeks višestruke deprivacije, postoje dva dopunska indeksa: indeks deprivacije s obzirom na dohodak koja utječe na djecu te indeks deprivacije s obzirom na dohodak koja utječe na starije osobe.

Tablica 2.: Domene, ponderi i pokazatelji za indekse deprivacije za Englesku iz 2015.

Deprivacija s obzirom na dohodak 22,5%	Odrasli i djeca u obiteljima koje primaju potporu dohotku Odrasli i djeca u obiteljima koje primaju naknadu na temelju dohotka za osobe koje aktivno traže posao Odrasli i djeca u obiteljima koje primaju naknadu za zapošljavanje i pomoć Odrasli i djeca u obiteljima koje ostvaruju pravo na odbitak poreza za djecu i dohodak od rada koji je niži od 60% medijana dohotka koji nije već uračunat Tražitelji azila u Engleskoj koji primaju pomoć za uzdržavanje, pomoć za stanovanje ili oboje		
Deprivacija s obzirom na zapošljavanje 22,5%	Podnositelji zahtjeva za naknadu za osobe koje aktivno traže posao u dobi od 18-59/64 godina Podnositelji zahtjeva za naknadu za zapošljavanje i potporu u dobi od 18-59/64 godina Podnositelji zahtjeva za naknadu u slučaju nesposobnosti za rad u dobi od 18-59/64 godina Podnositelji zahtjeva za naknadu za teški invaliditet u dobi od 18-59/64 godina Podnositelji zahtjeva za naknadu za njegovatelja u dobi od 18-59/64 godina		
Deprivacija s obzirom na zdravlje i invaliditet 13,5%	Potencijalno izgubljene godine života Komparativni omjer bolesti i invaliditeta Akutni morbiditet Poremećaji raspoloženja i tjeskobe		
Deprivacija s obzirom na obrazovanje, vještine i osposobljavanje 13,5%	Osnovnoškolsko obrazovanje: prosječna ocjena Srednjoškolsko obrazovanje: prosječna ocjena Izostanak u srednjoj školi Nastavak školovanja nakon 16. godine Upis u institucije visokog obrazovanja Odrasli s malim ili nikakvim kvalifikacijama u dobi od 25-59/64 godine Poznavanje engleskog jezika u dobi od 25-59/64 godine		
Kriminalitet 9,3%	Zabilježene stope kriminaliteta za: kaznena djela s elementima nasilja, tešku krađu provaljivanje, krađu, namjerno nanesenu štetu		
Prepreke stanovanju i uslugama 9,3%	Cestovna udaljenost do: pošte, osnovne škole, trgovine/supermarketa; ordinacije opće medicine Prenapučeno kućanstvo Beskućništvo Dostupnost stanovanja		
Deprivacija s obzirom na životno okruženje 9,3%	Stanovanje u lošim uvjetima Kuće bez centralnog grijanja Kvaliteta zraka Prometne nesreće		

Izvor: Ministarstvo za zajednice i lokalnu upravu (2015.); str. 18.

Razvoj i izrada tih indeksa temelje se na čvrstoj metodološkoj osnovi te slijede nakon sveobuhvatnog ispitivanja izvora podataka te osiguranja kvalitete tih izvora podataka i pokazatelja. Na primjer, posebna je pažnja posvećena odabiru pokazatelja kojima se mjere najvažnija obilježja deprivacije, koji se mogu redovito ažurirati i koji su specifični za pojedinu domenu. U okviru postupka izrade održan je velik broj savjetovanja s različitim dionicima, partnerima i drugim korisnicima. Povratne informacije dobivene od korisnika pažljivo se razmatraju.¹² Rezultati indeksa deprivacije za Englesku izraženi su u obliku različitih mjera, kao što su prosječni rezultat, prosječni rang, opseg i koncentracija na lokalnoj razini.

Iako je IVD koristan alata za mjerenje deprivacije u Engleskoj, potrebno je uzeti u obzir nekoliko ograničenja: 1. objavljeni rangovi i decili isključivo su relativni tako da se rezultati ne mogu neposredno tumačiti. Statistički podaci nisu izraženi u kardinalnim brojevima tako da se oni ne mogu usporediti u apsolutnom smislu; 2. postoje problemi u pogledu dinamike usporedbi: iako se indeks za neko područje može usporediti na razini jedne godine, stvarne usporedbe tijekom vremena složene su zbog zavisne prirode tog indeksa; 3. podaci za svaki od pokazatelja ne odnose se na jednu dosljednu vremensku točku (međutim, većina podataka za IVD iz 2015. odnosi se na fiskalnu godinu 2012./2013.). Nadalje, podaci će uvijek djelomično zaostajati za trenutačnom situacijom; i 4. budući da se za Englesku, Sjevernu Irsku, Škotsku i Wales izrađuju odvojeni indeksi, oni se ne mogu međusobno usporediti.

Škotska. Škotski indeks višestruke deprivacije (SIMD) sastoji se od sedam domena i 38 pokazatelja. Domene su sljedeće: i. zapošljavanje (3 pokazatelja), ii. dohodak (6 pokazatelja), iii. zdravlje (7 pokazatelja), iv. obrazovanje, vještine i osposobljavanje (5 pokazatelja), v. pristup uslugama u prostornom smislu (9 pokazatelja), vi. kriminalitet (6 pokazatelja) i vii. stanovanje (2 pokazatelja). Ponderiranje domena, izraženo u postotku ukupnog pondera, provodi se na sljedeći način: trenutačni dohodak (28 %), zapošljavanje (28 %), zdravlje (14 %), obrazovanje (14 %), pristup u prostornom smislu (9 %), kriminalitet (5 %) i stanovanje (2 %). Indeks se od 2004. ažurira svake dvije do tri godine, pri čemu je posljednja verzija objavljena 2012. SIMD-om iz 2012. obuhvaćeno je 6505 prostornih

¹² Na primjer, za ponderiranje domena, kako bi se izradio ukupni indeks višestruke deprivacije, na temelju triju empirijskih metoda za dobivanje pondera predlagala se zamjena pondera iz domene zapošljavanja (s 22,5 % na 13,5 %) i domene deprivacije s obzirom na zdravlje i invaliditet (s 13,5 % na 22,5 %). Međutim, tijekom savjetovanja koja su prethodila objavi indeksa utvrđeno je da je velika većina ispitanika bila za zadržavanje istih pondera. Zbog snažne potpore korisnika na kraju je odlučeno da se i dalje koriste postojeći ponderi.

jedinica te su ga lokalna tijela koristila za potrebe praćenja, posebno u pogledu deprivacija s obzirom na dohodak i zapošljavanje. Temeljni okvir za izradu indeksa temelji se na metodologiji koju je izradio Social Disadvantage Research Centre pri Sveučilištu u Oxfordu.

Njemačka. U Njemačkoj se deprivacija na razini okruga određuje prema njemačkom indeksu višestruke deprivacije (GIMD). Indeks se izrađuje prema primjeru iz Ujedinjene Kraljevine. Čini se da je izrada njemačkog indeksa više akademski pothvat koji dr. Werner Maier provodi sa svojim suradnicima te se uglavnom upotrebljava za kreiranje regionalnih razvojnih politika. Prvi GIMD izrađen je 2006., dok je drugi izračunan 2010. U nizu znanstvenih članaka GIMD je povezan s različitim zdravstvenim pokazateljima, kao što su pretilost, hipertenzija i dijabetes (na primjer, Maier i dr., 2015.).

Turska. Turskim socioekonomskim indeksom (SEDI) rangira se 81 regija prema svojoj razini socioekonomskog razvoja. To je jedini indeks koji se izrađuje primjenom analize glavnih komponenti korištenjem 61 pokazatelja. Pokazateljima su obuhvaćeni demografija, obrazovanje, zdravstvo, zapošljavanje, industrija, financije i drugi socijalni pokazatelji (tablica 3.). Rezultate objavljuje tursko Ministarstvo razvoja.¹³

Tablica 3.: Turska: indeks socioekonomskog razvoja (SEDI), 2003.

DEMOGRAFIJA	POLJOPRIVREDA
Ukupno stanovništvo	Vrijednost poljoprivredne proizvodnje u odnosu na stanovništvo u ruralnim područjima
Udio stanovništva koje živi u gradu	Udio poljoprivredne proizvodnje u nacionalnoj proizvodnji
Godišnja stopa rasta stanovništva	GRAĐEVINARSTVO
Gustoća stanovništva	Ukupan broj stambenih jedinica
Stopa plodnosti	Udio stambenih jedinica s vodom iz slavine
Prosječna veličina kućanstva	FINANCIJE
ZAPOSŁJAVANJE	Udio u ukupnom bruto domaćem proizvodu
Udio osoba zaposlenih u poljoprivrednom sektoru	Bruto domaći proizvod po stanovniku
Udio osoba zaposlenih u industrijskom sektoru	Broj podružnica banaka
Udio osoba zaposlenih u trgovinskom sektoru	Depoziti u bankama po stanovniku
Udio osoba zaposlenih u financijskom sektoru	Udio u ukupnim depozitima u banci
Udio stalno ili povremeno zaposlenih	Udio u ukupnim kreditima u banci
Udio stalnih ili povremenih zaposlenica	Poljoprivredni krediti u odnosu na stanovništvo u ruralnim područjima
Udio poslodavaca	Krediti za industrijske, komercijalne i turističke djelatnosti po stanovniku
OBRAZOVANJE	Općinski rashodi po stanovniku
Stopa pismenosti	Konsolidirani proračunski prihodi po stanovniku
Stopa pismenosti među ženama	Iznos poreza na dohodak i dobiti po stanovniku
Udio stanovništva s višim stupnjem obrazovanja	Ukupni javni rashodi po stanovniku
Stope školovanja u osnovnom obrazovanju	Iznos poticanih ulaganja po stanovniku
Stope školovanja u srednjoj školi	Ukupan izvoz po stanovniku
Stope školovanja u strukovnim i tehničkim školama	Ukupan uvoz po stanovniku

¹³ Za više informacija o izradi SEDI indeksa iz 2003. vidjeti Özaslan, Dincer i Özgür (2006.).

ZDRAVSTVO	INFRASTRUKTURA
Stopa smrtnosti novorođenčadi	Udio asfaltiranih cesta u ruralnim naseljima
Broj liječnika na 10000 osoba	Udio ukupnih asfaltiranih cesta
Broj stomatologa na 10000 osoba	Udio stanovništva u ruralnim naseljima s adekvatnom opskrbom pitke vode
Broj ljekarni na 10000 osoba	INDUSTRIJA
Broj bolničkih kreveta na 10000 osoba	Broj čestica u uređenim industrijskim zonama
OSTALI POKAZATELJI BOGATSTVA	Broj objekata u malim industrijskim područjima
Broj privatnih automobila na 10000 osoba	Broj objekata u proizvodnoj industriji
Broj motornih vozila na 10000 osoba	Godišnji prosječni broj zaposlenika u proizvodnji
Ukupna potrošnja električne energije po stanovniku	Kapacitet instaliranih električnih uređaja na kraju godine
Ukupan broj telefonskih uređaja po osobi	Dodana vrijednost u proizvodnoj industriji po stanovniku
Udio stanovništva koje ima karticu za besplatne zdravstvene usluge	Potrošnja električne energije u proizvodnoj industriji po stanovniku

Izvor: Özaslan, Dincer i Özgür (2006.).

Moldova. Republika Moldova upotrebljava metodologiju iz EU-SILC-a te nešto izmijenjenu verziju pokazatelja koji se koriste u Eurostatovu indeksu za mjerenje materijalne deprivacije. U toj se mjeri uzima u obzir mogu li si kućanstva priuštiti izbjegavanje kašnjenja plaćanja računa, mogu li podmiriti neočekivane izdatke, mogu li si priuštiti adekvatno grijanje, tjedan dana godišnjeg odmora, obrok s proteinima (ako to žele) te imaju li osobni automobil, perilicu za rublje, televizor i telefon. Osobe koje si ne mogu priuštiti najmanje tri od tih devet stavki smatraju se materijalno depriviranim, a za osobe koje si ne mogu priuštiti četiri od devet stavki smatra se da su u teškoj materijalnoj deprivaciji. Procjene iz ankete o potrošnji kućanstava u Moldovi za 2014. pokazuju da je više od polovine kućanstava materijalno deprivirano.¹⁴

Različiti indeksi koji su prethodno prikazani odgovaraju različitim zemljama i odnose se na različite razine agregiranja. Neki se izračunavaju na razini kućanstava (materijalna deprivacija prema Eurostatu), a drugi na razini malih područja (indeksi deprivacije za Englesku). Međutim, svima je cilj obuhvatiti životne standarde stanovništva. U nekim slučajevima tumačenje tog indeksa nije neposredno te se indeks možda ne može uspoređivati tijekom vremena. Iako Eurostatov indeks materijalne deprivacije može biti koristan za ocjenu deprivacije na nacionalnoj razini, njegova je relevantnost mala za mala geografska područja. Idealni indeks trebao bi se moći usporediti tijekom vremena i za različita područja, ali bi trebao biti relevantan i za mala geografska područja.

5. Prijedlog revidiranog indeksa višestruke deprivacije za Hrvatsku

U Hrvatskoj je proveden znatan broj istraživanja u području siromaštva i socijalne isključenosti. U različitim su izvorima zaključci vrlo slični: životni standard koji je u istočnoj i središnjoj Hrvatskoj

¹⁴ Ured Konferencije europskih statističara (2016.) – *Guide on Poverty Measurement (2016) Box 4.4 – Material Deprivation in the Republic of Moldova*

lošiji od prosjeka povezan je s manjom uspješnosti radnika na tržištu rada u tim regijama. Neke, ali nikako sve, razlike u prihodima u različitim regijama mogu se objasniti razlikama u osnovnim karakteristikama radnika.¹⁵ Utjecaj obrazovanja na vjerojatnost da će osoba pronaći zaposlenje najveći je u istočnoj Hrvatskoj, a zatim na jugu Jadranske Hrvatske. Obje regije imaju jedne od najnižih stopa zaposlenosti i najviših stopa nezaposlenosti u Hrvatskoj. Nakon detaljnijeg ispitivanja doprinosa radnika ljudskom kapitalu, izraženog u godinama njihova školovanja ili najvišeg stupnja obrazovanja, uočena je znatna razlika u prosječnim razinama obrazovanja u pojedinim regijama. Na primjer, radnici u Zagrebu, u prosjeku, imaju najmanje jednu godinu obrazovanja više od radnika u istočnoj i središnjoj Hrvatskoj.

Iako se velik dio regionalnih nejednakosti može objasniti doprinosom ljudskom kapitalu, vrlo su važne i razlike u karakteristikama među regijama. Na temelju izvješća „Ocjena životnog standarda” koje je Svjetska banka izradila 2006. vidljivo je da se oko 28 – 35 % ukupnih prosječnih razlika u plaći između Zagreba i Jadranske Hrvatske, s jedne strane, i Središnje Hrvatske (koja uglavnom uključuje istočni dio zemlje), s druge strane, može pripisati individualnim karakteristikama radnika, kao što je viši stupanj obrazovanja. Međutim, 65 % – 72 % zabilježenih razlika u plaći među regijama može se objasniti samo „drugim regionalnim čimbenicima”. Usklađivanjem za razlike u karakteristikama radnika u javnom i privatnom sektoru zabilježene razlike u plaći među regijama dodatno se mogu objasniti u oko 36 % – 59 % slučajeva. Budući da je udio zapošljavanja u javnim poduzećima obično veći u Zagrebu i Jadranskoj Hrvatskoj, time bi se djelomično mogle objasniti zabilježene nejednakosti u prihodima među regijama.

Regije koje zaostaju predmet su znatnog zanimanja i zabrinutosti kreatora javnih politika u svijetu, a posebno u Europi, u kojoj se znatna sredstava iz europskih strukturnih i investicijskih (ESI) fondova koriste za smanjenje regionalnih nejednakosti i izgradnju kohezije. Regije koje zaostaju često imaju slična obilježja: spori gospodarski rast, visoku nezaposlenost i siromaštvo, nisku efikasnost i produktivnost, slabu vanjsku trgovinu i općenito nizak fiskalni kapacitet za redistribuciju na lokalnoj razini. Uz to, često imaju nekoliko jednakih fizičkih karakteristika, uključujući činjenicu da nisu na obali, da imaju zastarjelu industriju i da im često nedostaju prirodni resursi (ili su ih iscrpili). Međutim, iako se kreatori politika slažu da je za uklanjanje regionalnih nejednakosti u životnim uvjetima potrebna javna intervencija, puno je manja suglasnost u pogledu najboljeg načina da se to učini, čak i u relativno

¹⁵ Svjetska banka (2006.) Hrvatska: Ocjena životnog standarda – promicanje socijalne uključenosti i regionalne jednakosti

sličnim zemljama. Za Hrvatsku je regionalni razvoj važan element programa politika, posebno jer su njezinim regijama koje zaostaju na raspolaganju znatna bespovratna sredstva iz EU-a kako bi im se pomoglo da dosegnu razinu razvijenosti drugih regija, pružila potpora u gospodarskom i socijalnom približavanju u područjima koja se suočavaju sa strukturnim poteškoćama te osigurala modernizacija sustava osposobljavanja radi promicanja zapošljavanja.

Ključan uvjet za bolje planiranje i praćenje socijalnog i gospodarskog razvoja bit će uspostavljanje statističke baze podataka i sustava za prikupljanje potrebnih pouzdanih statističkih podataka. Iako Državni zavod za statistiku uspostavlja okvir za prikupljanje statističkih podataka na nižim razinama, obično se ne prikupljaju informacije o socioekonomskim i demografskim karakteristikama na razini LAU2. Čak i procjena učestalosti siromaštva na regionalnoj razini u Hrvatskoj predstavlja izazov jer je veličina ukupnog uzorka za anketu o potrošnji kućanstava unutar svake županije premala za izradu procjena na željenoj razini preciznosti.¹⁶

Izrada indeksa višestruke deprivacije za mala područja (LAU2) temelji se na raspoloživim socioekonomskim podacima i podacima o pristupu infrastrukturi iz različitih izvora. Glavni su izvori odabrani administrativni registri, Državni zavod za statistiku te Popis stanovništva, kućanstava i stanova 2011. Indeks višestruke deprivacije osmišljen je kao dopuna informacijama o monetarnom siromaštvu na temelju izrađenih karata siromaštva.¹⁷

Predloženi IVD (slika 1.) temelji se na trima domenama deprivacije:


- ekonomskoj deprivaciji;
- socijalnoj deprivaciji;
- deprivaciji s obzirom na pristup uslugama

Te tri domene, zajedno sa svojim poddomenama, odabrane su kako bi se u obzir uzele deprivacije na koje općine mogu utjecati ispitivanjem zasebnih pokazatelja i njihova preklapanja.

¹⁶ Za potrebe ovog indeksa odabrano je siromaštvo prema potrošnji zbog brojnih nedostataka mjerenja dohotka. U slučaju raširenosti sive ekonomije i poljoprivrede, prednost se daje mjeri siromaštva prema potrošnji. U razvijenijim zemljama potrošnja je obično ujednačena tako da se na temelju informacija za kratka razdoblja može dobiti relevantna slika statusa kućanstva.

¹⁷ http://www.dzs.hr/ENG/DBHomepages/Personal%20Consumption%20and%20Poverty%20Indicators/Methodology_HBS_WB.pdf

Slika 1. Predloženi okvir indeksa višestruke deprivacije za Hrvatsku



Svaka je domena dodatno razrađena kroz osam poddomena. Popis domena, poddomena i pokazatelja prikazan je u tablici 4. Pokazatelji se odnose na najnovije podatke. Većina pokazatelja obuhvaća podatke za razdoblje 2011. – 2015. (tablica 4.), a velik dio njih koristi se za izradu skraćenog IVD-a za pilot-područja. Za neke se pokazatelje koriste podaci za tri godine kako bi se smanjio problem fluktuacija. Odabrani pokazatelji objavljuju se svake godine i dostupni su na razini LAU2. Neki važni pokazatelji koji su se razmatrali za uključivanje nisu bili dostupni; na primjer, stopa pismenosti isključena je zbog nedostatka brojnih podataka na razini kućanstava te se, stoga, nisu mogli izračunati pouzdani podaci na razini LAU2. Pokazatelji povezani sa zdravstvom isto tako uglavnom nisu bili dostupni na razini LAU2. Međutim, nakon pažljivog razmatranja korišteno je nekoliko drugih pokazatelja. Na primjer, za registraciju automobila, odraslo stanovništvo sa srednjoškolskim i višim obrazovanjem te učenike koji nisu položili maturu zabilježena je znatna korelacija s monetarnim siromaštvom.

6. Metodologija izračuna IVD-a

Pri osmišljavanju indeksa mogu se odabrati brojni elementi. Takvi odabiri metodološki mogu biti opravdani samo ako korisnik dobro razumije očekivanu svrhu konačne mjere, u ovom slučaju IVD-a. U indeksu koji je osmišljen isključivo kako bi se utvrdile deprivirane regije ili regije koje zaostaju mogu se odabrati određeni pokazatelji, metode standardizacije i postupci agregiranja koji će se znatno razlikovati od mjere koja je isključivo osmišljena za praćenje i ocjenu primjene intervencije. Vodeća načela u izradi IVD-a u okviru ovog projekta bila su usmjerena na osmišljavanje mjere koja bi se mogla koristiti za **utvrđivanje** depriviranih regija ili regija koje zaostaju, **ocjenu** prirode te deprivacije i lakšu procjenu prirode potrebnih intervencija, kao i za **praćenje** provedbe razvojnih strategija.

Ključni koncepti

Od Sena (1976.), mjerenje siromaštva i drugih deprivacija zamišljeno je u sljedeća dva koraka: utvrđivanje siromašnih i agregiranje informacija o siromaštvu u društvu.

U jednodimenzionalnom prostoru utvrđivanje siromašnih relativno je jasno: siromašne su osobe čije se ukupno postignuće ili resursi nalaze ispod linije siromaštva U_z , pri čemu indeks z samo signalizira da je riječ o liniji siromaštva koja je koristi u jednodimenzionalnom prostoru.

Za uobičajeni prvi korak u višedimenzionalnoj procjeni u nekoliko metodologija potrebno je odrediti prag svakog pokazatelja. Takav je prag minimalna razina koju osoba u toj dimenziji mora dosegnuti kako ne bi bila deprivirana. To se naziva granicom deprivacije.

U konkretnom slučaju u kojem su ponderi jednaki i odgovaraju zbroju dimenzija, rezultat je jednostavno broj deprivacija kojima je određena općina izložena. Kad god ponderi nisu jednaki, ali odgovaraju zbroju dimenzija, rezultat deprivacije prostorne jedinice l određuje se kao zbroj njezina ponderiranog broja deprivacija.

Tablica 4.: Hrvatska: predloženi pokazatelji indeksa višestruke deprivacije (IVD)

Domena	Poddomena	Pokazatelj	Izvor
Ekonomska	Tržište rada	Stopa zaposlenosti	Porezna uprava, Državni zavod za statistiku
Ekonomska	Tržište rada	Stopa sudjelovanja	Porezna uprava, Hrvatski zavod za zapošljavanje
Ekonomska	Tržište rada	Stopa nezaposlenosti	Porezna uprava, Hrvatski zavod za zapošljavanje
Ekonomska	Tržište rada	Udio umirovljenika u aktivnom stanovništvu	Porezna uprava
Ekonomska	Fiskalni kapacitet	Udio poreznih obveznika u stanovništvu	Porezna uprava, Državni zavod za statistiku
Ekonomska	Fiskalni kapacitet	Prosječni oporezivi dohodak po stanovniku	Porezna uprava, Državni zavod za statistiku
Ekonomska	Fiskalni kapacitet	Prihodi jedinica lokalne samouprave po stanovniku	Ministarstvo financija, Državni zavod za statistiku
Ekonomska	Fiskalni kapacitet	Rashodi jedinica lokalne samouprave po stanovniku	Ministarstvo financija, Državni zavod za statistiku
Ekonomska	Gospodarski razvoj	Broj aktivnih poslovnih subjekata po stanovniku	Državni zavod za statistiku
Ekonomska	Gospodarski razvoj	Broj aktivnih obrta po stanovniku	Državni zavod za statistiku
Ekonomska	Gospodarski razvoj	Udio zaposlenih u poljoprivredi	Ministarstvo poljoprivrede, Državni zavod za statistiku
Ekonomska	Gospodarski razvoj	Neto dohodak stanovništva po stanovniku	Porezna uprava, Državni zavod za statistiku
Ekonomska	Gospodarski razvoj	Broj registriranih osobnih automobila po stanovniku	Ministarstvo unutarnjih poslova, Državni zavod za statistiku
Socijalna	Socijalna zaštita	Udio korisnika ZMN-a u ukupnom stanovništvu	Ministarstvo za demografiju, obitelj, mlade i socijalnu politiku, Državni zavod za statistiku
Socijalna	Socijalna zaštita	Prosječni ZMN po stanovniku	Ministarstvo za demografiju, obitelj, mlade i socijalnu politiku, Državni zavod za statistiku
Socijalna	Socijalna zaštita	Doplatak za djecu po stanovniku	HZMO, Državni zavod za statistiku
Socijalna	Zdravstvo i obrazovanje	Udio osoba sa srednjoškolskim ili višim obrazovanjem	Državni zavod za statistiku
Socijalna	Zdravstvo i obrazovanje	Udio osoba koje koriste pomoć pri obavljanju svakodnevnih aktivnosti	Državni zavod za statistiku
Socijalna	Zdravstvo i obrazovanje	Udio učenika koji nisu položili maturu	NCVVO, Državni zavod za statistiku
Socijalna	Demografija	Kretanje stanovništva	Državni zavod za statistiku
Socijalna	Demografija	Stopa ekonomske ovisnosti	Državni zavod za statistiku
Socijalna	Demografija	Gustoća stanovništva	Državni zavod za statistiku
Socijalna	Demografija	Stopa smrtnosti	Državni zavod za statistiku
Fizička	Socijalne usluge	Stopa upisa u vrtiće	Državni zavod za statistiku
Fizička	Socijalne usluge	Udaljenost do doma zdravlja	HZZO
Fizička	Socijalne usluge	Otvorenost proračuna jedinica lokalne samouprave	Institut za javne financije
Fizička	Fizička infrastruktura	Udio kućanstava s pristupom javnoj vodoopskrbi	Državni zavod za statistiku
Fizička	Fizička infrastruktura	Udio kućanstava s pristupom javnoj odvodnji	Državni zavod za statistiku
Fizička	Fizička infrastruktura	Udio kućanstava s internetskim priključkom	Državni zavod za statistiku
Fizička	Fizička infrastruktura	Udio kućanstava bez centralnog grijanja	Državni zavod za statistiku
Fizička	Fizička infrastruktura	Gustoća cestovne mreže	OpenStreetMap, Državni zavod za statistiku

Dostupnost podataka i odabir pokazatelja

Za izračun višedimenzionalne mjere kao što je IVD potrebne su goleme količine podataka s obzirom na to da svaki pokazatelj mora biti dostupan za sve promatrane jedinice tijekom više godina. U najboljem slučaju, indeks bi trebao imati pokazatelje koji obuhvaćaju svaki tip deprivacije iz iscrpnog popisa domena. S druge strane, dostupnost podataka u Hrvatskoj (što je zapravo ograničenje koje se u određenom stupnju javlja u svim zemljama) ograničava broj statističkih analiza koje se mogu koristiti, izračun indeksa i promatrane jedinice.

Budući da ne postoji anketa kućanstava koja bi bila reprezentativna na razini općina i koja bi sadržavala sve potrebne varijable za izračun indeksa višestruke deprivacije, kako bi se konsolidirala baza podataka s 53 pokazatelja koji su odabrani iz početnog popisa u kojem ih je bilo uključeno preko 200¹⁸, korištena je kombinacija podataka iz administrativnih registara, podataka iz popisa stanovništva i procjena za mala područja. Konačan indeks sastoji se od 31 pokazatelja.

Osnovni kriteriji odabira ove skupine pokazatelja bili su davanje prednosti onim pokazateljima iz administrativnih registara koji se mogu godišnje ažurirati te korelacija tih varijabli s monetarnim siromaštvom (za više pojedinosti vidjeti tablice 5. i 6.). Glavni razlog za takav izbor bila je potreba da se izradi mjera koja bi se mogla koristiti za praćenje i evaluaciju implementacije resursa koji se dodjeljuju regijama koje se smatraju depriviranim. Uzimajući u obzir te ciljeve, bilo je vrlo važno prednost dati onim izvorima podataka koji se mogu često ažurirati, no nije bilo moguće odabrati samo one pokazatelje koji se mogu ažurirati na godišnjoj razini, pa je osam konačnih pokazatelja izrađeno na temelju popisa stanovništva koji se ažurira tek svakih 10 godina¹⁹.

Vodeći računa o tome koliko su praćenje i evaluacija važni, bilo je važno utvrditi one pokazatelje koji bi bili povezani s očekivanim ishodima i *outputima* očekivanih intervencija, a ne samo s običnim *inputima*.

¹⁸ Pokazatelji su odabrani na temelju ukupne korelacije sa siromaštvom prema potrošnji na razini općina.

¹⁹ U Hrvatskoj se i dalje koristi popis stanovništva prema načelu prisutnog stanovništva (*de facto*), dok se u brojnim drugim državama članicama EU-a, kao što je Slovenija, već sada koriste popisi stanovništva na temelju administrativnih registara koji se mogu ažurirati svake godine.

Tablica 5.: Sažetak odabranih pokazatelja po tipu, učestalosti, domeni, poddomeni i izvoru podataka

Domena	Poddomena	Izvor	Ishod		Output		Input		Ukupno	
			10 godina	Godišnje	10 godina	Godišnje	Stalno	Godišnje		
Ekonomska	Tržište rada	Porezna uprava, Državni zavod za statistiku		2					2	
		Porezna uprava, Hrvatski zavod za zapošljavanje		1					1	
		Porezna uprava				1			1	
	Fiskalni kapacitet	Porezna uprava, Državni zavod za statistiku				2			2	
		Ministarstvo financija, Državni zavod za statistiku				2			2	
		Državni zavod za statistiku						2	2	
	Gospodarski razvoj	Ministarstvo poljoprivrede, Državni zavod za statistiku		1					1	
		Porezna uprava, Državni zavod za statistiku		1					1	
		Min. unutarnjih poslova, Državni zavod za statistiku		1					1	
Socijalna	Socijalna zaštita	Ministarstvo za demografiju, obitelj, mlade i socijalnu politiku, Državni zavod za statistiku					2		2	
		Hrvatski zavod za mirovinsko osiguranje, Državni zavod za statistiku				1			1	
	Zdravstvo i obrazovanje	Državni zavod za statistiku	1		1				2	
		Nacionalni centar za vanjsko vrednovanje obrazovanja, Državni zavod za statistiku				1			1	
	Demografija	Državni zavod za statistiku		3	1				4	
	Fizička	Socijalne usluge	Državni zavod za statistiku				1			1
			Hrvatski zavod za zdravstveno osiguranje					1		1
Institut za javne financije								1	1	
Fizička infrastruktura		Državni zavod za statistiku			4				4	
	OpenStreetMap*, Državni zavod za statistiku			1				1		
Ukupno			1	9	7	8	3	3	31	

*Pokazatelj gustoće cestovne mreže dostupan je samo za 2016. pa se stoga navodi u popisu pokazatelja koji se ažuriraju svakih 10 godina, no on se u budućnosti može i češće ažurirati.

Kako bi se ispitala robusnost specifikacije, korištena su dva modela za IVD. U prvoj je specifikaciji (model 1) korišten 31 ključni pokazatelj i, ako je to bilo izvedivo, trogodišnji pomični prosjek pokazatelja za koje su podaci dostupni. Druga specifikacija (model 2) obuhvaća samo godišnje vrijednosti i uglavnom se koristila kako bi se ispitala robusnost rezultata.

Tablica 6.: Korelacija odabranih pokazatelja s monetarnim siromaštvom (dohodovno i prema potrošnji) za 2015. (trogodišnji prosjek)

Domena	Poddomena	Naziv pokazatelja	CONS FGT0	CONS FGT1	CONS FGT2	INC FGT0	INC FGT1	INC FGT2
Ekonomska	Gospodarski razvoj	Neto dohodak stanovništva po stanovniku	-0.565	-0.565	-0.554	-0.713	-0.684	-0.660
		Broj aktivnih poslovnih subjekata po stanovniku	-0.532	-0.489	-0.455	-0.520	-0.480	-0.452
		Broj aktivnih obrta po stanovniku	-0.542	-0.516	-0.492	-0.431	-0.414	-0.400
		Broj registriranih osobnih automobila po stanovniku	-0.585	-0.575	-0.558	-0.693	-0.665	-0.641
		Udio zaposlenih u poljoprivredi	0.431	0.433	0.426	0.359	0.349	0.340
	Fiskalni kapacitet	Prosječni oporezivi dohodak po stanovniku	-0.577	-0.575	-0.562	-0.715	-0.683	-0.659
		Prihodi jedinica lokalne samouprave po stanovniku	-0.380	-0.346	-0.324	-0.324	-0.303	-0.290
		Rashodi jedinica lokalne samouprave po stanovniku	-0.534	-0.494	-0.463	-0.461	-0.436	-0.417
		Udio poreznih obveznika u stanovništvu	-0.496	-0.487	-0.474	-0.604	-0.584	-0.569
	Tržište rada	Stopa zaposlenosti	-0.574	-0.577	-0.566	-0.716	-0.695	-0.673
		Stopa sudjelovanja	-0.136	-0.140	-0.140	-0.257	-0.229	-0.211
		Udio umirovljenika u aktivnom stanovništvu	0.325	0.327	0.318	0.382	0.382	0.370
		Stopa nezaposlenosti	0.689	0.692	0.680	0.779	0.780	0.768
		Stopa ekonomske ovisnosti	0.267	0.278	0.276	0.329	0.323	0.313
Socijalna	Demografija	Stopa smrtnosti	0.341	0.334	0.321	0.271	0.257	0.242
		Gustoća stanovništva	-0.195	-0.185	-0.175	-0.209	-0.187	-0.173
		Kretanje stanovništva	-0.418	-0.401	-0.379	-0.410	-0.404	-0.390
		Udio učenika koji nisu položili maturu	0.292	0.282	0.269	0.313	0.295	0.280
	Zdravstvo i obrazovanje	Udio osoba sa srednjoškolskim ili višim obrazovanjem	-0.622	-0.622	-0.613	-0.579	-0.561	-0.547
		Udio osoba koje koriste pomoć pri obavljanju akt.	0.495	0.481	0.458	0.756	0.718	0.684
	Socijalna zaštita	Prosječni ZMN po stanovniku	0.524	0.549	0.556	0.573	0.603	0.614
		Doplatka za djecu po stanovniku	0.579	0.568	0.550	0.580	0.563	0.548
		Udio korisnika ZMN-a u ukupnom stanovništvu	0.436	0.436	0.430	0.559	0.575	0.575
Fizička	Socijalne usluge	Stopa upisa u vrtiće	-0.442	-0.426	-0.407	-0.506	-0.472	-0.446
		Otvorenost proračuna jedinica lokalne samouprave	-0.149	-0.143	-0.137	-0.218	-0.196	-0.183
		Udaljenost do doma zdravlja	0.099	0.107	0.107	0.198	0.181	0.167
	Fizička infrastruktura	Gustoća cestovne mreže	-0.116	-0.132	-0.137	-0.223	-0.221	-0.214
		Udio kućanstava s pristupom javnoj odvodnji	-0.330	-0.308	-0.288	-0.359	-0.326	-0.305
		Udio kućanstava s pristupom javnoj vodoopskrbi	-0.322	-0.323	-0.319	-0.390	-0.375	-0.362
		Udio kućanstava s internetskim priključkom	-0.585	-0.571	-0.551	-0.550	-0.524	-0.502
		Udio kućanstava bez centralnog grijanja	-0.149	-0.155	-0.148	-0.373	-0.348	-0.324

Standardizacija

Pokazatelji se, nakon odabira, moraju standardizirati kako bi bili usporedivi. Pokazatelji se odabiru na temelju relevantnosti, pouzdanosti i kvalitete podataka. Kako bi se povećala robusnost IVD-a u odnosu na pojavu netipičnih vrijednosti i olakšalo tumačenje rezultata po domenama, poddomenama i pokazateljima, standardizirali smo pokazatelje po **percentilnom rang**u općina. Pokazatelj varira između 0 i 1, pri čemu vrijednost 1 znači da je općina na vrhu 1 % deprivacije svih općina u Hrvatskoj za taj pokazatelj i obratno, vrijednost 0 znači da je općina na dnu 1 % svih općina u zemlji.

Kod većine kompozitnih indeksa javlja se problem dimenzionalnosti, s obzirom na to da se različiti pokazatelji utvrđuju korištenjem jasno određenih jedinica, kao što su stope, gustoće, udjeli ili razine. Imajući u vidu takve razlike, ključno je primijeniti metodu kojom bi se svi pokazatelji standardizirali kako bi se uspostavila usporediva dimenzija prije agregiranja. S tim ciljem, tim je ispitao brojne druge mogućnosti i preporučuje korištenje načela percentilnog ranga.

Glavna je prednost tog načela činjenica da njegovim korištenjem rezultati postaju dostupni brojim dionicima, npr. kreatorima politika, političarima, novinarima i stručnjacima; uz to, učestalo se koristi u akademskoj i korporativnoj zajednici te, naposljetku, omogućava neposredno tumačenje načina na koji je svaka pojedinačna jedinica povezana s većom skupinom. Sve su to vrlo važna polazišta za brzo provođenje reformi na temelju tog pokazatelja. Uz to, načelo percentilnog ranga ima određene tehničke prednosti, na primjer: 1. ekstremne vrijednosti distribucije ne utječu toliko jako na percentile; 2. ne ovise o izboru specifičnih funkcija gustoće vjerojatnosti u odnosu na aritmetičku sredinu i standardnu devijaciju koje zahtijevaju podatke s normalnom distribucijom; i 3. percentili se mogu izračunati čak i ako su podaci iskrivljeni.

Pri tumačenju percentilnih rangova treba biti oprezan: iako neka općina može biti na dnu ranga (tj. imati vrijednost 1), to ne znači da ima nisku razinu određenog pokazatelja. Položaj u distribuciji jednostavno rangira razinu svake općine u odnosu na ostale općine u zemlji.

U tablici 7. prikazan je jednostavan numerički primjer za zemlju sa šest općina (od A do F) za koje se računa višedimenzionalni indeks na temelju šest pokazatelja (od I1 do I6). Kao što je vidljivo iz primjera, različiti pokazatelji imaju posve drukčije ljestvice, što odražava činjenicu da se neki pokazatelji izražavaju u razinama, drugi u udjelima i ostali u omjerima. Prvi je korak u svakoj standardizaciji osigurati da se svi pokazatelji mogu tumačiti na isti način u odnosu na koncept koji se nastoji izmjeriti – u ovom slučaju, deprivaciju. IVD-om za Hrvatsku ta se procjena može empirijski potkrijepiti s obzirom na to da su dostupni podaci iz najnovije karte siromaštva koja je korištena za procjenu korelacije svakog pokazatelja sa siromaštvom (kao što je prikazano u tablici 6.). Zatim se te informacije koriste kako bi se utvrdilo odražava li visoka vrijednost dobar ili loš pokazatelj, ovisno o odnosu između tog pokazatelja i siromaštva. Na primjer, visoka nezaposlenost i velik broj visokoobrazovanih osoba moraju se diferencirati pri rangiranju općina na temelju svakog pokazatelja. Visoka vrijednost pokazatelja nezaposlenosti bit će povezana s visokom razinom siromaštva te će se stoga smatrati da pripada višim percentilima te deprivacije. S druge strane, visoka vrijednost pokazatelja visokoobrazovanih osoba može biti povezana s niskom razinom siromaštva te će stoga ta općina biti u nižim percentilima deprivacije.

Tablica 7.: Apsolutna vrijednost pokazatelja i empirijska korelacija s kartom siromaštva

	Pokazatelj						Korelacija sa siromaštvom					
	I1	I2	I3	I4	I5	I6	I1	I2	I3	I4	I5	I6
A	10	5	23,2	0,89	0,89	-0,9	-0,4	0,8	0,6	0,4	-0,1	0,03
B	8	5	34,6	0,1	0,1	-0,7						
C	4	5	10,5	1	1	0,7						
D	3	8	34,9	0,34	0,34	0,2						
E	1	3	45,5	0,23	0,23	0,4						
F	0,5	3	28	0,45	0,65	-0,3						

Red (1=pozitivno; 0 negativno)					
I1	I2	I3	I4	I5	I6
0	1	1	1	0	1

Sve vrijednosti iz tablice 7. pretvorene su u percentilni rang korištenjem formule za percentilni rang navedene u jednadžbi 1. Tablica 8. prikazuje konačne vrijednosti za percentilne rangove za svaku općinu u našem primjeru. Percentilni rang apsolutne vrijednosti može se tumačiti kao postotak vrijednosti u njezinoj distribuciji koji je jednak ili niži od nje. Na primjer, stopa nezaposlenosti u općini koja je veća ili jednaka stopi nezaposlenosti od 75 % hrvatskih općina bit će na 75. percentilu, odnosno, njezin percentilni rang iznositi će 0,75. Percentilni rang prikazuje postotak općina koje su rangirane niže od prikazane općine, tako da više vrijednosti upućuju na višu razinu deprivacije i uvijek će se nalaziti u rasponu od 0 do 1.

Jednadžba 1. Formula za izračun percentilnog ranga

$$PR = \left(\frac{X_p}{n} \right) 100$$

PR = percentilni rang. Rezultat će biti postotak.

X_p = položaj rezultata u distribuciji. Započnite s najnižom vrijednosti i brojite primjere dok ne dosegnete rezultat koji se razmatra. Pri određivanju X_p obvezno uključite rezultat

koji se razmatra i sve one koji imaju jednaku vrijednost.

n = ukupan broj primjera u distribuciji

Tablica 8.: Rang i percentilni rang apsolutnih vrijednosti iz tablice 7.:

	Rang						Percentili					
	I1	I2	I3	I4	I5	I6	I1	I2	I3	I4	I5	I6
A	1	3	2	5	2	1	0,0	0,4	0,2	0,8	0,2	0,0
B	2	3	4	1	6	2	0,2	0,4	0,6	0,0	1,0	0,2
C	3	3	1	6	1	6	0,4	0,4	0,0	1,0	0,0	1,0
D	4	6	5	3	4	4	0,6	1,0	0,8	0,4	0,6	0,6
E	5	1	6	2	5	5	0,8	0,0	1,0	0,2	0,8	0,8
F	6	1	3	4	3	3	1,0	0,0	0,4	0,6	0,4	0,4

Utvrđivanje i agregiranje

Budući da nas zanima **mjera deprivacije**, u sljedećem ćemo koraku **cenzurirati svaki pokazatelj** u odnosu na graničnu vrijednost ispod koje bi se općina **smatrala depriviranom** prema tom pokazatelju. Granične vrijednosti mogu biti **apsolutne ili relativne**. S obzirom na to da su naše jedinice analize općine, može se činiti da je teško odrediti prirodnu graničnu vrijednost, osim ako nisu povezane s ciljevima određenih politika (koje bi se mogle provoditi u budućnosti). Zbog svega smo toga odabrali **relativnu graničnu vrijednost** (vrijednost medijana svakog pokazatelja) (tablica 9.). Iz perspektive implementacije politika, kao obrazloženje može se koristiti činjenica da su odabrane općine u donjoj polovini distribucije zemlje prema tom pokazatelju.

Tablica 9.: Granična vrijednost za svakog pokazatelja

Granica (relativni [medijan])					
I1	I2	I3	I4	I5	I6
0,5	0,5	0,5	0,5	0,5	0,5

Nakon odabira i primjene graničnih vrijednosti pokazatelja na svaku matricu pokazatelja, slijedi agregiranje pokazatelja. Riječ je o zadnjem koraku u analizi koji treba provesti zato što nas ne zanimaju samo deprivirane općine, nego one koje su sustavno deprivirane. Najjednostavniji je način agregiranja indeksa višestruke deprivacije brojanje deprivacija ili korištenje prosjeka pokazatelja prema kojima je općina deprivirana. U tablici 10. prikazana je matrica deprivacija. Rezultat je umnožak rangova percentila navedenih u tablici 8., koji se pretvara u matricu deprivacija nakon što primijenimo granične vrijednosti iz tablice 9.

Korelacija sa siromaštvom upućuje na smjer deprivacije. Ako je korelacija pokazatelja i siromaštva negativna, poželjnije su više vrijednosti tog pokazatelja. Po istoj analogiji, ako je korelacija pokazatelja sa siromaštvom negativna, smatrat će se da je neko područje deprivirano ako je percentilni rang tog pokazatelja ispod granične vrijednosti. Stoga se općina smatra depriviranom ($I[x]=1$) u slučaju bilo koje vrijednosti ispod 0,50 (ispod granice u slučaju negativne korelacije sa siromaštvom; iznad granice ako je korelacija pozitivna), a smatra se da nije deprivirana ($I[x]=0$) ako je pokazatelj iznad granične vrijednosti od 0,50 (u slučaju negativne korelacije sa siromaštvom, ispod vrijednosti ako je korelacija pozitivna). Rezultati konačnog agregiranja navode se u posljednja dva stupca i mogu se prikazati kao broj ili prosjek.

Tablica 10.: Matrica cenzurirane deprivacije

Matrica deprivacije (cenzurirana)							Broj deprivacija	Prosjek deprivacija
	I1	I2	I3	I4	I5	I6		
A	1	0	0	1	1	0	3	0,50
B	1	0	1	0	0	0	2	0,33
C	1	0	0	1	1	1	4	0,67
D	0	1	1	0	0	1	3	0,50
E	0	0	1	0	0	1	2	0,33
F	0	0	0	1	1	0	2	0,33

Alternativno, može se računati i **prosječna razlika u deprivaciji**, odnosno **prosječna udaljenost percentila svakog pokazatelja u odnosu na granicu** za svaki pokazatelj deprivacije. Kao i u prethodnim primjerima, i taj se pokazatelj može, ali i ne mora, ponderirati. Glavna je razlika u toj metodi to da je konačan indeks osjetljiv na činjenicu da **sve općine nisu jednako deprivirane**, s obzirom na to da će neke u prosjeku biti bliže graničnoj vrijednosti, a druge mnogo udaljenije od nje. Konačno, treba razmotriti i **kvadrat prosječne razlike u deprivaciji**. U tom se slučaju, u skladu s prethodno navedenom definicijom prosječne razlike u deprivaciji, računa njezin kvadrat. Glavna je svrha tog postupka dodatno **povećati osjetljivost** konačnog indeksa na razlike u razini deprivacije među odabranim općinama.

U skladu s metodom prosječne razlike u deprivaciji, indeks je prosjek ne samo broja deprivacija, nego i prosječne udaljenosti (ili kvadrata prosječne udaljenosti) općine od granične vrijednosti deprivacije prikazane u tablici 9. Glavna je razlika između mjera razlike (tablica 11.) i kvadrata razlike (tablica 12.) činjenica da potonja mjera daje veći ponder općinama koje su teže pogođene deprivacijom. Iz

perspektive kreiranja politika i odnosa s javnošću, preporuka je koristiti mjeru razlike u deprivaciji, s obzirom na to da je dovoljno osjetljiva na distribuciju, ali se istovremeno može i jednostavno objasniti zainteresiranoj javnosti.

Tablica 11.: Matrica cenzurirane razlike u deprivaciji

	Matrica razlika (cenzurirana)						Razlika u deprivaciji
	I1	I2	I3	I4	I5	I6	
A	0,5	0,0	0,0	0,3	0,3	0,0	0,18
B	0,3	0,0	0,1	0,0	0,0	0,0	0,07
C	0,1	0,0	0,0	0,5	0,5	0,5	0,27
D	0,0	0,5	0,3	0,0	0,0	0,1	0,15
E	0,0	0,0	0,5	0,0	0,0	0,3	0,13
F	0,0	0,0	0,0	0,1	0,1	0,0	0,03

Tablica 12.: Matrica cenzuriranog kvadrata razlike u deprivaciji

	Matrica kvadrata razlika (cenzurirano)						Kvadrat razlike u deprivaciji
	I1	I2	I3	I4	I5	I6	
A	0,3	0,0	0,0	0,1	0,1	0,0	0,07
B	0,1	0,0	0,0	0,0	0,0	0,0	0,02
C	0,0	0,0	0,0	0,3	0,3	0,3	0,13
D	0,0	0,3	0,1	0,0	0,0	0,0	0,06
E	0,0	0,0	0,3	0,0	0,0	0,1	0,06
F	0,0	0,0	0,0	0,0	0,0	0,0	0,00

Ponderiranje pokazatelja

Ponderiranje bilo koje višedimenzionalne mjere značajan je korak koji ima jasne učinke na konačno rangiranje. U najboljem slučaju, ponderiranjem se ispravno dodjeljuje intrinzična ili konceptualna vrijednost pokazatelja. Ovisno o ciljevima indeksa, neki se ponderi mogu nerazmjerno ponderirati kako bi se istaknula neka područja od posebne važnosti ili interesa za zemlju. Treba razmotriti i na koji će se način postupak ponderiranja koji utječe na konačan oblik indeksa objasniti zainteresiranoj javnosti. Iz perspektive kreiranja politika, složene metode ponderiranja mogu otežati razumljivost rezultata i primjenjivost mjere.

U IVD-u se koristi mehanizam ponderiranja na dvije razine kojim se svakoj domeni i svakoj poddomeni u određenoj domeni dodjeljuju jednaki ponderi. Na konceptualnoj razini, tim se

postupkom trima domenama deprivacije (ekonomskoj, socijalnoj i pristupu uslugama) pridaje jednaka važnosti, što je u skladu s ciljem indeksa, odnosno izravnim sveobuhvatnim mjerenjem blagostanja tako da ga općinske vlasti mogu koristiti. Dodjela jednakih pondera poddomenama u svakoj domeni može se objasniti činjenicom da poddomene imaju specifične značajke i služe kao dopuna, što teoretski znači da imaju jednaku razinu važnosti. Ipak, treba imati na umu da pokazatelji unutar jedne poddomene s više pokazatelja imaju niži ponder.

Na primjer, u domeni javnih usluga, poddomene „socijalne usluge” i „fizička infrastruktura” sadržavaju tematski različite pokazatelje koji su ključni za ispravno funkcioniranje jedinica lokalne samouprave. Sustav ponderiranja na dvije razine dovodi do pokazatelja s različitim ponderima, zbog čega raščlamba konačnog proizvoda postaje manje jasna. S druge strane, s obzirom na to da se broj pokazatelja ne razlikuje značajnije među poddomenama i da je količina poddomena uglavnom jednaka, razumljivo je da se javlja razlika među ponderima na razini pokazatelja.

Glavni je razlog za taj odabir pondera činjenica da se njima dodjeljuje jednaka važnost aktivnostima svih resornih ministarstava koja će na kraju biti odgovorna za upravljanje intervencijama koje će vjerojatno utjecati na različite domene i poddomene.

Tablica 13.: Matrica ponderirane cenzurirane deprivacije

Matrica deprivacije (cenzurirana)							Broj deprivacij a	Ponderiran i prosjek deprivacija
Domena 1a		Domena 2a						
	I1	I2	I3	I4	I5	I6		
A	1	0	0	1	1	0	3	0,50
B	1	0	1	0	0	0	2	0,38
C	1	0	0	1	1	1	4	0,63
D	0	1	1	0	0	1	3	0,50
E	0	0	1	0	0	1	2	0,25
F	0	0	0	1	1	0	2	0,25
Ponder domene	0,5		0,5					
Ponder pokazatelja (ukupno)	0,25	0,25	0,12 5	0,12 5	0,12 5	0,12 5		

Na primjer, pretpostavimo da pokazatelji 1 i 2 u tablici 10. pripadaju jednoj domeni (1a), a pokazatelji 3, 4, 5 i 6 drugoj (2a). Svaka domena ima jednak ponder od $\frac{1}{2}$. Svi pokazatelji u svakoj domeni imaju

jednak ponder, što znači da će pokazatelji u domeni 1a imati ponder od $\frac{1}{2}$, a njihov ponder u ukupnom IVD-u bit će $\frac{1}{4}$. U slučaju domene 2a, svaki će pokazatelj imati ponder od $\frac{1}{4}$, a njihov ponder u ukupnom IVD-u iznosit će $\frac{1}{8}$. Tablica 13. prikazuje pripadajući indeks broja deprivacija nakon ponderiranja.

Vremenska usporedba i upotreba fiksnih percentilnih rangova

U standardizaciji IVD-a percentilni rangovi koriste se radi rješavanja problema dimenzionalnosti u različitim pokazateljima. Stoga se, za svakog pokazatelja, vrijednost pripisana svakoj općini pretvara u njezin relativni položaj s obzirom na percentilni rang na razini općina prema određenom pokazatelju. Važno je napomenuti da se svaki percentilni rang svakog pokazatelja povezuje s apsolutnom graničnom vrijednosti za svaki specifični percentil. Primjena tradicionalnog načela percentilnog ranga bila bi problematična s vremenskog stajališta zbog njegove zavisne prirode, čime bi se mogla prikriti važna poboljšanja tijekom vremena u apsolutnom smislu koja ne bi bila uključena u mjeru percentilnog ranga.

Kako bismo riješili to pitanje, odlučili smo fiksirati apsolutne granične vrijednosti svakog percentilnog ranga za sve pokazatelje u određenom trenutku (npr. u 2011. ili pomični prosjek za razdoblje između 2009. i 2011.). Prednost je te metode što se na taj način može koristiti standardizacija pokazatelja prema percentilnom rangu, ali se istovremeno zadržava i mogućnost mjerenja napretka tijekom vremena. Sa stajališta tumačenja važno je napomenuti da bi svaku mjeru fiksnog percentilnog ranga trebalo tumačiti u smislu uspješnosti u odnosu na referentnu godinu, pri čemu se zadržavaju usporedbe za svaku pojedinu godinu. Na primjer, ako granica (vrijednost medijana za općine) u 2011. za nezaposlenost iznosi 20 %, općina sa stopom nezaposlenosti iznad te vrijednosti u bilo kojoj godini smatrat će se depriviranom.

U tablici 14. prikazan je numerički primjer koncepta fiksnog percentilnog ranga. Na primjer, za određenu skupinu općina može se simulirati promjena pokazatelja IVD-a (jedna dimenzija) tijekom vremena, odnosno između 2011. i 2013. Za obje godine (primjer 1. i primjer 2.) iskazujemo vrijednost i rang u pojedinoj godini, percentilni rang i IVD (korištenjem granice od 0,5). Za primjer 3. prikazana je vrijednost fiksnog percentilnog ranga za 2011. korištenjem vrijednosti za 2013. te nastali IVD za 2013. korištenjem tog fiksnog percentilnog ranga. Primjer 4. prikazuje promjenu IVD-a korištenjem relativnog i fiksnog načela. Najprije je važno primijetiti da se tijekom tog razdoblja prosječna vrijednost pokazatelja smanjila s 35 % na 5 %. To je veliko smanjenje; međutim, nisu se sve općine kretale u istom smjeru. Iako su općine A i H povećale svoju vrijednost (čime se pokazatelj pogoršao), sve su

ostale općine bolje ili su ostale na istoj razini predmetnog pokazatelja. Glavna razlika između fiksnog i relativnog načela može se točno utvrditi za vrijednosti općina A i H, čija je vrijednost pokazatelja 2013. iznosila 31 % odnosno 11 %. Korištenjem percentilnog ranga za 2013. te su općine zabilježile percentilne rangove 1,00 i 0,88 odnosno fiksne percentilne rangove 0,63 i 0,50. Stoga IVD za 2011. (mjera razlike) iznosi 0,16, a ako koristimo mjeru relativnog percentilnog ranga, ekvivalentni IVD za 2013. iznosi 0,11. Istovremeno se ista mjera IVD-a za 2013., primjenom percentilnog ranga fiksnog korištenjem graničnih vrijednosti za 2011., smanjuje na 0,02. Iz tog numeričkog primjera vidljiva je važnost primjene fiksnog percentilnog ranga za potrebe praćenja napretka tijekom vremena.

Tablica 14.: Numerički primjer utjecaja promjene percentilnog ranga i fiksnog percentilnog ranga između 2011. i 2013. za simulirane općine.

Općina	Primjer 1.				Primjer 2.				Primjer 3.		Primjer 4.	
	2011.				2013.				2013. fiksirana u 2011.		Promjena	
	Vrijednost	Rang	Percentilni rang	Relativni IVD	Vrijednost	Rang	Percentilni i rang	Relativni IVD	Fiksni rang percentila	IVD	Relativni IVD	Fiksni IVD
A	11%	4	0,50	0,00	31%	8	1,00	0,50	0,63	0,13	-0,50	-0,13
B	31%	5	0,63	0,13	0%	1	0,13	0,00	0,13	0,00	0,50	0,50
C	51%	6	0,75	0,25	0%	1	0,13	0,00	0,13	0,00	0,63	0,62
D	9%	3	0,38	0,00	0%	1	0,13	0,00	0,13	0,00	0,25	0,25
E	78%	7	0,88	0,38	0%	1	0,13	0,00	0,13	0,00	0,75	0,75
F	100%	8	0,50	0,50	0%	1	0,13	0,00	0,13	0,00	0,88	0,87
G	0%	1	0,00	0,00	0%	1	0,13	0,00	0,13	0,00	0,00	-0,01
H	0%	1	0,00	0,00	11%	7	0,88	0,38	0,50	0,00	-0,75	-0,38
Prosjeck	35%		0,55	0,16	5%		0,33	0,11	0,24	0,02	0,22	0,31

7. Primjena IVD-a za utvrđivanje, ocjenjivanje i praćenje provedbe intervencija u depriviranim regijama

Kao što je prethodno navedeno, vodeće načelo koje se slijedilo pri osmišljavanju IVD-a bilo je kreirati višedimenzionalni indeks za mjerenje razine deprivacije na razini općina. Njegova je glavna svrha olakšati utvrđivanje prioriternih područja, pomoći pri procjeni vrsta deprivacije s kojima se suočava svaka općina u smislu domena i poddomena te pratiti poboljšanje ostvareno tijekom vremena.

Najočitiji i najprirodniji primjer primjene IVD-a jest utvrđivanje depriviranih regija i regija koje zaostaju. Analitičar se u tom pogledu može usmjeriti na prostornu prirodu pokazatelja. Velik dio interaktivne aplikacije izrađen je imajući na umu tu primjenu (vidjeti Prilog 1. i *online* webinare). U pogledu prostorno-vremenskih obrazaca višestruke deprivacije, na slici 2. prikazan je rezultat jaza IVD-a korištenjem trogodišnjeg pomičnog prosjeka fiksnih percentila u 2011. za razdoblje 2009. – 2011. (slika 2.a.1.) i razdoblje 2013. – 2015. (slika 2.a.2.). Pojedinačni rezultati IVD-a mogu se

koristiti u kontinuiranom, kao izravna vrijednost pokazatelja, ili kategoričkom obliku, kao što MRRFEU koristi svoj indeks regionalnog razvoja grupiranjem pokazatelja u nekoliko odabranih kategorija.


Ista se mjera može koristiti i za utvrđivanje obrazaca prostorne koncentracije deprivacije u Hrvatskoj, no u tom slučaju fokus više nije na rezultatima ili kategorijama tih rezultata, nego na prostorno ponderiranoj vrijednost indeksa i mjeri u kojoj je on iznad ili ispod nacionalnog prosjeka. Na slikama 2.b.1. i 2.b.2. crvenom su bojom prikazana područja u žarišnoj točki, odnosno područja čija je prostorna ponderirana vrijednost IVD-a statistički značajno niža od nacionalnog prosjeka, dok su plavom bojom prikazane regije u kojima je prostorni ponderirani IVD značajno viši od nacionalnog prosjeka (u okviru 1. predstavljena je korištena metoda). U kontekstu tog postupka na rezultate općina neće utjecati samo njihova deprivacija, nego i deprivacija njihovih susjeda, s obzirom na to da će se socioekonomske prilike vjerojatno razlikovati ovisno o vanjskim čimbenicima povezanim s uspješnim ili neuspješnim okruženjem. Taj pristup može biti koristan i pri osmišljavanju određenih vrsta intervencija koje će vjerojatno dovesti do pozitivnih vanjskih čimbenika. U tim će okolnostima kreatori politika možda htjeti odrediti područje obuhvata svake intervencije na temelju obrazaca koncentracije, čime bi se omogućila maksimalna internalizacija svih pozitivnih vanjskih čimbenika do kojih željena intervencija može dovesti.

Rezultat IVD-a može se koristiti i za utvrđivanje prostornih netipičnih vrijednosti. U decentraliziranim sustavima rješenja određenih razvojnih izazova često već mogu postojati jer su određena lokalna tijela možda već pronašla način da poboljšaju svoje rezultate. U tim je okolnostima ključno imati uspostavljen sustav koji služi kao pomoć pri utvrđivanju tih mogućih predvodnika i njihovih lokacija. Prostorna heterogenost rezultata IVD-a može biti vrijedan izvor informacija za kreatore politika kako bi mogli utvrditi općine za koje se čini da su neuobičajeno bolje ili lošije od očekivanog. Te informacije mogu biti vrijedne za utvrđivanje općina za studije slučaja i detaljnije analize. Na slikama 2.c.1. i 2.c.2. plavom su bojom prikazane općine čiji je rezultat IVD-a znatno viši (pozitivne netipične vrijednosti) od njihovih susjeda, a crvenom one koje imaju niži IVD od susjednih općina (negativne netipične vrijednosti)

Slika 2. Korištenje IVD-a za utvrđivanje prostornih obrazaca deprivacija i netipičnih vrijednosti


(a.1) rezultat jaza IVD-a za 2011.

(trogodišnji pomični prosjek, fiksni)



(b.1) rezultat jaza IVD-a za 2011. – žarišna točka

(trogodišnji pomični prosjek, fiksni)




(c.1) rezultat jaza IVD-a za 2011. – netipične vrijednosti

(trogodišnji pomični prosjek, fiksni)



(a.2) rezultat jaza IVD-a za 2015.

(trogodišnji pomični prosjek, fiksni)



(b.2) rezultat jaza IVD-a za 2015. – žarišna točka

(trogodišnji pomični prosjek, fiksni)



(c.2) rezultat jaza IVD-a za 2015. – netipične vrijednosti

(trogodišnji pomični prosjek, fiksni)



Okvir 1. Getis-Ord G_i^* analiza žarišnih i hladnih točaka

Prostorni obrasci deprivacije i distribucije programa vjerojatno neće biti nasumični. Jedna je od svrha ove analize pokazati kakva je prostorna koncentracija deprivacije ili bilo kojeg drugog atributa, pri čemu se za svaku pojedinačnu lokaciju utvrđuju prostorni klasteri (Kondo, 2016.). U kontekstu analize *outputa* karte IVD-a, s pomoću Getis-Ord statistike istraživači mogu utvrditi područja s najvećom koncentracijom IVD-a te dobiti korisne informacije o tome kamo treba usmjeriti sredstva.

Ovom se statističkom analizom vrijednosti za pojedine lokacije zajedno sa susjednim vrijednostima unutar određenog radijusa uspoređuju s očekivanom vrijednosti svih lokacija u promatranom području. Velika je vjerojatnost da lokalna jedinica neće biti žarišna točka, osim ako je okružena drugim jedinicama sa sličnim visokim vrijednostima.

Statistička analiza Getis-Ord računa se s pomoću sljedeće formule:

$$G_i^* = \frac{\sum_{j=1}^N w_{ij} x_j - \bar{x} \sum_{j=1}^N w_{ij}}{S \sqrt{\frac{N \sum_{j=1}^N w_{ij}^2 - (\sum_{j=1}^N w_{ij})^2}{N-1}}}$$

pri čemu je x_j vrijednost atributa (na primjer, IVD-a) u lokaciji j , a w_{ij} udaljenost između lokacija i i j . N je ukupan broj lokacija u analizi. Konačno:

$$\bar{x} = \frac{\sum_{j=1}^N x_j}{N}$$
$$S = \sqrt{\frac{\sum_{j=1}^N x_j^2}{N} - (\bar{x})^2}$$


Kako se broj lokacija povećava, distribucija analize približava se standardnoj normalnoj distribuciji (Kondo, 2016.). Dakle, rezultat je z vrijednost (*z-score*) na temelju koje se mogu utvrditi veći klasteri hladnih (negativne z vrijednosti manje od -1,645) i žarišnih (pozitivne z vrijednosti veće od 1,645) točaka. Veće vrijednosti upućuju na veći intenzitet prostorne koncentracije.

Izvor: okvir 1. izvješća u okviru projekta savjetodavnih usluga uz naknadu (RAS): „Hrvatska: Profil siromašnih na razini županija, općina i gradova”


Kao što je prethodno prikazano, rezultat IVD-a može se koristiti za utvrđivanje prostornih obrazaca deprivacije, izravnom klasifikacijom općina ili njihovim žarišnim i hladnim točkama ili netipičnim vrijednostima. Međutim, na temelju višedimenzionalnosti IVD-a i njegova agregiranja kreatori politika mogu

istražiti koje su domene ili poddomene IVD-a relevantnije za procjenu prirode deprivacija s kojima se suočava svaka općina. Stoga se mogu primijeniti svi prostorno-vremenski pristupi prikazani na slici 2. u svakoj domeni, poddomeni ili pokazatelju korištenom u izračunu IVD-a. Osim toga, može se dobiti uvid u razlike na razini IVD-a u svim regijama u Hrvatskoj. Na slici 3. prikazano je kako se svaka poddomena IVD-a u Slavoniji razlikuje od ostalih poddomena u ostatku Hrvatske.

Slika 3. Prosječna razina višestruke deprivacije prema poddomeni i regiji



Slika 4. Prosječna razina višestruke deprivacije prema poddomeni i regiji



Vrijednosti na desnoj strani pokazuju povećanje razine deprivacije u odnosu na ostatak zemlje, a vrijednosti na lijevoj strani niže razine deprivacije. Na slici je vidljivo da su razine višestruke deprivacije u nekoliko poddomena sustavno više u Slavoniji te da su to općine koje su zabilježile posebno

loše rezultate u smislu njihove razine ovisnosti o sustavu socijalne zaštite te pokazatelja vezanih za zdravlje i obrazovanje. Zabrinjavajući je i jaz u domeni fiskalnog kapaciteta između Slavonije i ostatka Hrvatske.

IVD se može koristiti i za praćenje vremenske ocjene deprivacije. Kako što je vidljivo na slici 4., višestruka deprivacije zadržava se u Slavoniji na višoj razini u odnosu na ostatak zemlje, iako je nedavno ostvaren određeni napredak. Takvo se kretanje može izraditi i na razini svake domene, poddomene i pokazatelja.

8. Završne napomene

Indeksi višestruke deprivacije mogu biti dopuna mjerama monetarnog siromaštva jer uključuju različite, ali povezane mjere deprivacije. Mjera siromaštva za EU 2020. temeljit će se na materijalnoj deprivaciji, fiktivnoj nezaposlenosti te pokazateljima rizika od siromaštva i isključenosti. Stoga su indeksi koji prikazuju te informacije dobili na važnosti te se u Hrvatskoj koriste u kreiranju politika na temelju dokaza. Nekoliko država članica EU-a dopunilo je svoje teritorijalne politike prostornim indeksima razvijenosti. Ako su dobro strukturirane, te se mjere mogu koristiti ne samo za utvrđivanje depriviranih regija ili regija koje zaostaju, nego i za ocjenu prirode njihovih deprivacija i praćenje napretka tijekom vremena. Kako bi pokazatelj bio učinkovit, postupak njegova osmišljavanja jednako je važan kao i sam pokazatelj. Vrlo je važno i preuzimanje tehničke i političke odgovornosti za bilo koju od tih mjera.

Iz hrvatskog indeksa višestruke deprivacije vidljive su razine deprivacije u različitim dimenzijama, grupirane prema poddomenama u kojima se agregiraju pojedinačni pokazatelji. Za izradu usporedivih aplikacija najprije je potrebno utvrditi dogovoreni skup pokazatelja i definicija. U Hrvatskoj je izradu IVD-a vodio MRRFEU, koji je organizirao savjetovanja s različitim dionicima na državnoj te nacionalnoj akademskoj razini.

U budućnosti će biti ključno nastaviti poboljšavati kvalitetu temeljnih podataka za izračun IVD-a, kao i ispitivati mogućnost uključivanja dodatnih pokazatelja koji postanu relevantni za kreiranje politika.

Prilog 1. Aplikacija

Bodovna ljestvica IVD-a: Pokazuje rezultate IVD-a odabranih općina za željene domene, poddomene i pokazatelje.

1. korak: Odaberite specifikacije za **MJERU IVD-a**, **STANDARD IVD-a** i **MJERU SIROMAŠTVA**. Poželjne opcije su kvadrat jaza, fiksni percentili za 2011. odnosno jaz siromaštva prema potrošnji.

2. korak: Odaberite željene **ŽUPANIJE** ili **PODRUČJA** i odredite **GODINU ANALIZE**. Godina analize može biti **JEDNA GODINA** ili **3-GODIŠNJI POMIČNI PROSJEK** ovisno o željenoj opciji.


Poverty Measure: Consumption based Poverty Gap | IMD Measure: Gap | IMD Standard: 2011 Anchored Percentile | Island: (All) | Muntown: (All) | Namecounty: (All) | Year: 3y2015

0.02 | 0.27 Consumption based Poverty Gap vs IMD Gap using 2011 Anchored Percentile (3y2015)

Poverty Map
(Consumption based Poverty Gap)



Prikazuje se lokacija odabranih općina na karti Hrvatske.



3. korak: Kliknite na općine kako biste popunili tablicu u nastavku. Kako biste odabrali više županija, držite „Ctrl” dok ih odabirete klikom.

4. korak: Odaberite željenu vrstu vrijednosti koju želite prikazati u tablici.


Domain	Subdomain	Indicator	Kistanje	Staro Petrovo Selo	Rešetari	Pribislavec	Rakovica
Economic	Economic development	Net income of the population	0.99	0.79	0.74	0.60	0.22
		Number of active business ent.	0.87	0.84	0.81	0.21	0.61
		Number of active crafts per ca.	0.26	0.68	0.67	0.90	0.63
		Number of registered personal	0.99	0.75	0.89	0.49	0.16
		Share of agricultural employm.	0.88	0.74	0.43	0.26	0.48
Fiscal capacity		Average taxable income per c.	0.99	0.89	0.76	0.62	0.19
		Local government expenditure	0.60	0.91	0.92	0.87	0.24
		Local government revenues p.	0.99	0.73	0.87	0.79	0.30
		Share of taxpayers in the pop.	0.94	0.55	0.52	0.28	0.00
		Employment rate	0.99	0.91	0.84	0.48	0.17
Labor Market		Participation rate	0.83	0.54	0.48	0.39	0.02
		Pension system dependency r.	0.99	0.93	0.85	0.18	0.86
		Unemployment rate	1.00	0.97	0.95	0.64	0.68
		Average GMB per capita	1.00	0.78	0.81	0.62	0.57
		Child allowance per capita	0.76	0.83	0.76	0.91	0.53
Social	Social protection	Share of GMB beneficiaries in	1.00	0.95	0.95	0.75	0.74
		Proportion of students failing	0.86	0.82	0.82	0.37	0.96
		Share of people with secondar	0.92	0.77	0.67	0.55	0.57
		Share of persons using the as.	0.92	0.99	0.82	0.65	0.63
		Demography	0.99	0.79	0.82	0.62	0.75
Physical	Social services	Dependency ratio	0.95	0.79	0.40	0.19	0.81
		Mortality rate	0.97	0.88	0.77	0.26	0.59
		Population change	0.92	0.64	0.32	0.05	0.96
		Distance to the primary health	0.92	0.73	0.25	0.25	0.45
		Enrollment rate in kindergarte	0.56	0.65	0.99	0.55	0.99
Physical infrastructure		Transparency of local govern.	0.33	0.33	0.47	0.47	0.12
		Road density	0.78	0.60	0.06	0.17	0.94
		Share of households with Inter	0.96	0.72	0.67	0.37	0.44
		Share of households with acc.	0.40	0.99	0.35	0.37	0.99
		Share of households without c	0.33	0.99	0.92	0.58	0.28
			0.99	0.53	0.30	0.03	0.20

Prikazuje se percentilni rang svake odabrane općine te će se svaka ćelija obojiti ovisno o njezinoj vrijednosti. Zelena boja označava viši rang, dok crvena označava niži rang.


Promjena IVD-a po županijama: Prikazuje se promjena ukupnih rezultata IVD-a za odabrane općine tijekom željenog razdoblja.

1. korak: Odaberite specifikacije za **MJERU IVD-a**, **STANDARD IVD-a** i **MJERU SIROMAŠTVA** za željene županije. Poželjne opcije su kvadrat jaza, fiksni percentili za 2011. odnosno jaz siromaštva prema potrošnji.

2. korak: Odredite **ŽELJENO RAZDOBLJE** odabirom početne i završne godine.



Change IMD Gap using 2011 Anchored Percentile between 3y2011 and 3y2015 by Counties



Note: Dashboard and indexes prepared by the World Bank with data provided by CROSTAT and MRDEF. Project co-financed by the European union from the European fund for Regional development.

Bodovna ljestvica promjene IVD-a:

Pokazuje promjenu rezultata IVD-a odabranih županija za željene domene, poddomene i pokazatelje.

1. korak: Odaberite specifikacije za **MJERU IVD-a**, **STANDARD IVD-a** i **MJERU SIROMAŠTVA**. Poželjne opcije su kvadrat jaza, fiksni percentili za 2011. odnosno jaz siromaštva prema potrošnji.

2. korak: Odredite **ŽELJENO RAZDOBLJE** odabirom početne i završne godine.

3. korak: Odaberite željene **ŽUPANIJE**

Poverty Measure: Consumption based Poverty Gap
IMD Measure: Gap
IMD Standard: 2011 Anchored P...
Start Year: 3y2011
End Year: 3y2015
Level or Change: Change
Namecounty: (All)


Change of the 2011 Anchored Percentile IMD Gap between 3y2011 and 3y2015



Poverty Map
(Consumption based Poverty Gap)



Change IMD Gap using 2011 Anchored Percentile between 3y2011 and 3y2015



Bjelovarsko-bilogorska
Brodsko-posavska
Dubrovačko-neretvanska
Grad Zagreb
Istarska
Karlovačka
Koprivničko-križevačka
Krapinsko-zagorska
Ličko-severska
Međimurska
Oseječko-baranjska
Požariško-slavonska
Primorsko-goranska
Šibensko-kninska
Sisačko-moslavačka
Splitško-dalmatinska
Varaždinska
Virovitičko-podravska
Vukovarsko-srijemska
Zadarska
Zagrebačka

3. korak: Kliknite na **NAZIVE OPĆINA** kako biste ih odabrali na **GRAFIKONU** i u **TABLCI** u nastavku

Change of the Indicators use to construct the 2011 Anchored Percentile IMD Gap between 3y2011 and 3y2015

		IMD Input Standard				IMD Input Standard color for val...			
		2011 Anchored Percentile				2011 Anchored Percentile			
Domain	Subdomain	Indlabel	Brodski Stupnik	Touj	Gorani	Unešić	Šolta	Maruševac	
Economic	Economic development	Net income of the population per capita	-0.10	0.00	-0.04	-0.08	-0.03	-0.03	
		Number of active business entities per capita	-0.26	-0.02	-0.20	-0.24	-0.03	-0.11	
		Number of active crafts per capita	-0.04	-0.03	-0.01	0.00	0.11	0.14	
		Number of registered personal cars per capita	-0.17	-0.14	-0.06	-0.14	-0.01	-0.20	
		Share of agricultural employment	0.00	0.00	-0.01	-0.03	-0.01	0.00	
	Fiscal capacity	Average taxable income per capita	-0.11	0.02	-0.04	-0.07	-0.03	-0.01	
		Local government expenditures per capita	-0.14	0.21	0.01	-0.25	-0.06	0.04	
		Local government revenues per capita	-0.12	-0.02	-0.34	-0.28	0.00	0.05	
		Share of taxpayers in the population	-0.53	-0.35	-0.52	-0.47	-0.07	-0.30	
		Labor Market	Employment rate	-0.16	0.11	-0.06	-0.35	0.16	-0.04
Participation rate	-0.20		0.05	-0.21	-0.37	0.14	-0.10		
Pension system dependency ratio	0.07		0.07	0.04	-0.01	0.02	0.02		
Unemployment rate	-0.05		0.09	0.04	0.04	0.12	0.06		
Dependency ratio	0.00		0.00	0.01	0.01	-0.01	0.00		
Social	Demography	Mortality rate	0.43	-0.03	-0.24	-0.01	0.03	0.19	
		Population change	0.28	0.22	-0.25	0.08	0.00	0.32	
		Population density	0.06	0.02	0.03	0.01	-0.04	0.01	
		Proportion of students failing Matura exam	0.50	0.00	-0.02	0.29	0.00	0.33	
		Share of people with secondary education or higher	0.00	0.00	0.00	0.00	0.00	0.00	
	Health and education	Share of persons using the assistance in performing daily activities	0.00	0.00	0.00	0.00	0.00	0.00	
		Social protection	Average GMB per capita	0.06	0.01	0.00	0.00	-0.01	-0.01
			Child allowance per capita	-0.09	-0.07	-0.05	0.05	-0.03	-0.05
			Share of GMB beneficiaries in the population	-0.05	-0.05	0.05	0.03	0.08	-0.01
			Distance to the primary health center	0.00	0.00	0.00	0.00	0.00	0.00
Enrollment rate in kindergartens	-0.17		0.00	-0.10	-0.37	0.11	0.04		
Physical	Social services	Transparency of local government budgets	-0.23	0.00	0.00	-0.29	0.00	0.00	
		Physical infrastructure	Road density	0.00	0.00	0.00	0.00	0.00	0.00
			Share of households with access to public sewerage	0.00	0.00	0.00	0.00	0.00	0.00
			Share of households with access to public water supply	0.00	0.00	0.00	0.00	0.00	0.00
			Share of households with Internet connection	0.00	0.00	0.00	0.00	0.00	0.00
	Share of households without central heating		0.00	0.00	0.00	0.00	0.00	0.00	

4. korak: Odaberite željene **ULAZNE STANDARDE IVD-a** koje želite prikazati u tablici

Prikazuje se promjena percentilnog ranga svake odabrane općine te će se svaka ćelija obojiti ovisno o njezinoj vrijednosti. Zelena boja označava viši rang, dok crvena označava niži rang.

Note: Dashboard and indexes prepared by the World Bank with data provided by CROSTAT and MRDEF. Project co-financed by the European union from the European fund for Regional development.

Literatura

- Ured Konferencije europskih statističara (2016.) – „Guide on Poverty Measurement”. Ekonomska komisija Ujedinjenih naroda za Europu (UNECE)
- Državni zavod za statistiku (2016.a). Procjena siromaštva za mala geografska područja prema potrošnji: metodološko izvješće.
https://www.dzs.hr/Hrv/DBHomepages/Osobna%20potrosnja%20i%20pokazatelji%20siromastva/Metodologija_HBS_WB.pdf
- Državni zavod za statistiku (2016.b). Procjene dohodovnog siromaštva za mala geografska područja u Hrvatskoj: metodološki izvještaj.
https://www.dzs.hr/Hrv/DBHomepages/Osobna%20potrosnja%20i%20pokazatelji%20siromastva/Metodologija_SILC_WB.pdf
- Department for Communities and Local Government (2015.) The English Indices of Deprivation 2015; Technical Report; dostupno na <https://www.gov.uk/government/publications/english-indices-of-deprivation-2015-technical-report>.
- Eurostat (2009.). „What can be Learned from Deprivation Indicators in Europe”, Methodologies and Working papers, izdanje 2009.
- Fusco A., A. C. Guio, i E. Marlier (2013.) „Building a Material Deprivation Index in a Multinational Context: Lessons from the EU Experience”, u V.Bérenger i F. Bresson (ur.), *Poverty and Social Exclusion Around the Mediterranean Sea*, Economic Studies in Inequality, Social Exclusion and Well-Being 9. New York: Springer Science+Business Media.
- Guio A. C. (2009.) „What can be learned from deprivation indicators in Europe? „Eurostat Methodologies and Working Papers, izdanje 2009. Luxembourg: Ured za službene publikacije Europskih zajednica.
- Institut za javne financije (2016.). Otvorenost proračuna županija, gradova i općina: studeni 2015. – ožujak 2016., Newsletter 107, srpanj 2016.
- Maier W., Siegel M. i Mielck A. (2015.) „Individual Income, Area Deprivation, and Health: Do Income-Related Health Inequalities Vary by Small Area Deprivation?” *Health Economics*, 24(11), str. 1523–1530.
- Özaslan M., B. Dincer i H. Özgür (2006.) „Regional Disparities and Territorial Indicators in Turkey: Socio-Economic Development Index (SEDI)”, rad predstavljen na: 46. Kongresu Europskog udruženja za regionalna istraživanja (ERSA) u Volosu, Grčkoj. Dostupno na: <https://ideas.repec.org/p/wiw/wiwrse/ersa06p858.html>
- Svjetska banka (2006.) Hrvatska: Ocjena životnog standarda

Prilog 1. Opis pokazatelja koji se koriste za izračun IVD-a

IVD se sastoji od 31 pokazatelja kojima je obuhvaćeno razdoblje 2009. – 2015. U pogledu periodičnosti IVD se izračunava na dva načina. Prvi je način korištenje vrijednosti pokazatelja za svaku godinu, a drugi korištenjem trogodišnjeg pomičnog prosjeka pokazatelja. Ako podaci za konkretnog pokazatelja nisu dostupni za svaku godinu, koristimo dostupne podatke za najbližu godinu. Svi su podaci dostupni na razini općine/grada.

Pokazatelji korišteni za izračun IVD-a i podijeljeni prema domenama i poddomenama opisani su u nastavku.

Domena: Ekonomska

Poddomena Tržište rada

Stopa zaposlenosti izračunava se kao broj zaposlenih podijeljen s brojem stanovnika u dobi od 15 do 64 godine. Broj zaposlenih pokazatelj je koji se dobiva iz evidencije Porezne uprave o obveznicima poreza na dohodak (broj zaposlenika na temelju obrazaca ID/JOPPD uvećan za broj samozaposlenih na temelju godišnjih poreznih prijava). Stanovništvo u dobi od 15 do 64 godine u svakoj godini procjenjuje se na temelju popisa stanovništva 2011. i procjena broja stanovnika na kraju godine na razini općine/grada tako da se udio radno sposobnog stanovništva (15 – 64) u ukupnom stanovništvu iz popisa stanovništva 2011. primjenjuje na procijenjeni ukupni broj stanovnika u određenoj godini.

Stopa sudjelovanja izračunava se kao broj aktivnog stanovništva (zaposleni i nezaposleni) podijeljen s brojem stanovnika u dobi od 15 do 64 godine. Broj zaposlenih pokazatelj je koji se dobiva iz evidencije Porezne uprave o obveznicima poreza na dohodak (broj zaposlenika na temelju obrazaca ID/JOPPD uvećan za broj samozaposlenih na temelju podnesenih godišnjih poreznih prijava). Broj nezaposlenih temelji se na podacima Hrvatskog zavoda za zapošljavanje o nezaposlenosti; koristi se godišnji prosjek. Stanovništvo u dobi od 15 do 64 godine procjenjuje se na temelju popisa stanovništva 2011. i procjena broja stanovnika na razini općine/grada na kraju godine. Radno sposobno stanovništvo (15 – 64) iz popisa stanovništva 2011. primjenjuje se na procijenjeni broj stanovnika u određenoj godini kako bi se dobio procijenjeni broj radno sposobnih stanovnika.

Stopa nezaposlenosti izračunava se kao broj nezaposlenih podijeljen s brojem aktivnog stanovništva. Broj nezaposlenih uzima se iz evidencije Hrvatskog zavoda za zapošljavanje, kao godišnjih prosjek. Aktivno stanovništvo zbroj je zaposlenih i nezaposlenih. Broj zaposlenih pokazatelj je koji se uzima iz evidencije Porezne uprave o obveznicima poreza na dohodak (zaposleni i samozaposleni).

Udio umirovljenika u aktivnom stanovništvu je omjer broja uplatitelja u mirovinski sustav i broja umirovljenika. Broj uplatitelja približno odgovara broju zaposlenih prema evidenciji Porezne uprave (broj zaposlenika na temelju obrazaca ID/JOPPD uvećan za broj samozaposlenih na temelju godišnjih poreznih prijava). Broj umirovljenika također se uzima iz evidencije Porezne uprave koja se temelji na obrascima ID/JOPPD.

Poddomena Fiskalni kapacitet

Udio poreznih obveznika u stanovništvu pokazatelj je koji se temelji na podacima Porezne uprave o ukupnom broju obveznika poreza na dohodak podijeljenom s brojem stanovnika u određenoj godini. Podatke o broju stanovnika osigurava Državni zavod za statistiku.

Prosječni oporezivi dohodak po stanovniku odnosi se na ukupan oporezivi dohodak stanovnika općine podijeljen s brojem stanovnika u određenoj godini. Oporezivi dohodak je dohodak nakon uplate doprinosa za zdravstveno i mirovinsko osiguranje i prije plaćanja poreza na dohodak. Uključuje prihode koji podliježu oporezivanju osobnog dohotka uvećane za dobit od samozaposlenja (u slučajevima kad su samozaposleni obvezni plaćati porez na dobit). Podatke o oporezivom dohotku na razini općine/grada osigurava Porezna uprava, a podatke o broju stanovnika Državni zavod za statistiku.

Prihodi jedinica lokalne samouprave po stanovniku odnose se na ukupne proračunske prihode jedinica lokalne samouprave po stanovniku umanjene za iznose bespovratnih sredstava i donacija, kao i na prihode na temelju posebnih ugovora, kao što je sufinanciranje koje se stanovnicima pruža za posebne projekte, dodatne prihode na temelju transfera iz proračuna središnje države za decentralizirane funkcije ili priljev novca od prodaje imovine, podijeljene s brojem stanovnika. Podatke o proračunskim prihodima prikuplja Ministarstvo financija. Procjene broja stanovnika osigurava Državni zavod za statistiku.

Rashodi jedinica lokalne samouprave po stanovniku izračunavaju se na temelju podataka Ministarstva financija o ostvarenjima proračuna lokalne samouprave. U tom se pokazatelju uzima u obzir vrijednost ukupnih rashoda, što uključuje tekuće rashode države i neto stjecanje nefinancijske imovine (ulaganja). Ukupni rashodi podijeljeni su s brojem stanovnika prema procjeni Državnog zavoda za statistiku.

Poddomena Gospodarski razvoj

Broj aktivnih poslovnih subjekata po stanovniku izračunava se kao ukupan broj aktivnih poslovnih subjekata (podaci iz registra trgovačkih društava) podijeljen s brojem stanovnika. Podatke osigurava Državni zavod za statistiku.

Broj aktivnih obrta po stanovniku izračunava se kao ukupan broj aktivnih obrta podijeljen s brojem stanovnika. Podatke osigurava Državni zavod za statistiku.

Udio zaposlenih u poljoprivredi odnosi se na broj zaposlenih u poljoprivredi podijeljen s brojem stanovnika. Broj zaposlenih u poljoprivredi uzima se iz registra Ministarstva poljoprivrede i uključuje osobe kojima je poljoprivreda glavni ili jedini izvor prihoda. Procjene broja stanovnika izrađuje Državni zavod za statistiku.

Neto dohodak stanovništva po stanovniku pokazatelj je koji se temelji na podacima Porezne uprave o dohotku stanovništva nakon oporezivanja (baza podataka o osobnom dohotku na temelju obrazaca ID/JOPPD) koji se dijeli s brojem stanovnika (podaci Državnog zavoda za statistiku) u određenoj godini.

Broj registriranih osobnih automobila po stanovniku izračunava se kao broj registriranih osobnih automobila podijeljen s brojem stanovnika u određenim općinama. Izvor podataka o registriranim automobilima je Ministarstvo unutarnjih poslova, dok podatke o broju stanovnika osigurava Državni zavod za statistiku.

Domena: Socijalna

Poddomena Socijalna zaštita

Udio korisnika ZMN-a u ukupnom stanovništvu pokazatelj je koji se temelji na podacima Ministarstva za demografiju, obitelj, mlade i socijalnu politiku. Izračunava se na temelju broja korisnika socijalne pomoći (korisnika zajamčene minimalne naknade (ZMN) u 2014. i kasnije te korisnika pomoći za uzdržavanje do 2014.) koji su registrirani u svim lokalnim centrima za socijalnu skrb. Lokalni centar obično obuhvaća nekoliko općina. Broj stanovnika izračunava se za svako područje obuhvaćeno lokalnim centrom te se broj korisnika dijeli s brojem stanovnika. Udio korisnika zatim se pripisuje svakoj općini/gradu u nadležnosti centra. Alternativno, isti se pokazatelj uzima iz informacijskog sustava za upravljanje (MIS) tog Ministarstva. Podaci iz tog sustava pouzdani su za 2014. i dalje te se mogu upotrebljavati umjesto podataka koji se temelje na informacijama centara za socijalnu skrb.

Prosječni mjesečni ZMN po stanovniku izračunava se na temelju mikropodataka Ministarstva za demografiju, obitelj, mlade i socijalnu politiku. Ukupna masa naknada za zajamčenu minimalnu naknadu (ZMN) mjesečno po općini/gradu dijeli se s brojem stanovnika koji je procijenio Državni zavod za statistiku. Podaci su dostupni za 2014. i kasnije.

Doplatak za djecu po stanovniku izračunava se na temelju informacija o broju djece koja primaju doplatak za djecu i prosječnom iznosu naknade po općini/gradu (podaci Hrvatskog zavoda za mirovinsko osiguranje), čime se dobiva ukupna masa naknada po lokalnoj jedinici koja se zatim dijeli s procijenjenim brojem stanovnika (podaci koje osigurava Državni zavod za statistiku).

Poddomena Zdravstvo i obrazovanje

Udio osoba sa srednjoškolskim ili višim obrazovanjem u radno sposobnom stanovništvu izračunava se na temelju podataka iz popisa stanovništva 2011. Izvor je Državni zavod za statistiku.

Udio osoba koje koriste pomoć druge osobe pri obavljanju svakodnevnih aktivnosti izračunava se na temelju podataka iz popisa stanovništva 2011. Podaci se preuzimaju iz mikropodataka DZS-a prema popisu stanovništva, upitnik 1., pitanje broj 44.

Udio učenika koji nisu položili maturu uzima se iz baze podataka koju vodi Nacionalni centar za vanjsko vrednovanje obrazovanja. Podaci se odnose na prvo pristupanje maturi i udio učenika koji nije položio (ocjena 1) najmanje jedan od tri glavna ispita (matematiku, hrvatski, strani jezik). Pokazatelj je udio učenika koji nisu položili ispite u ukupnom broju učenika koji su prvi put polagali maturu. Pokazatelj se dobiva iz baze podataka projektnog tima.

Poddomena Demografija

Kretanje stanovništva odnosi se na godišnje kretanje stanovništva. Podaci o broju stanovnika 2011. – 2015. procjenjuju se na temelju popisa stanovništva 2011. i dostupnih podataka o prirodnim kretanjima stanovništva. Podaci za 2009. – 2011. procjene su broja stanovnika koje se temelje na popisu stanovništva 2001. i informacijama o kasnijim kretanjima stanovništva. Godišnje promjene između 2011. i 2012. te nakon toga izračunavaju se primjenom procjena broja stanovnika na temelju popisa stanovništva 2011., dok se promjene za ranije godine izračunavaju primjenom procjena broja stanovnika na temelju popisa stanovništva za 2001.

Stopa ekonomske ovisnosti demografski je pokazatelj koji se izračunava kao ovisno stanovništvo (stanovništvo koje nije radno sposobno) podijeljeno s radno sposobnim stanovništvom. Ovisno stanovništvo definira se kao stanovništvo u dobi od 0 – 14 godina te stanovništvo u dobi od 65 i više godina, dok je radno sposobno stanovništvo stanovništvo u dobi od 15 – 64 godine. Udio svake dobne skupine u ukupnom stanovništvu izračunava se na temelju popisa stanovništva 2011. Podatke osigurava Državni zavod za statistiku.

Gustoća stanovništva odnosi se na podatke iz popisa stanovništva 2011. o ukupnom broju stanovnika po kvadratnom kilometru. Podatke osigurava Državni zavod za statistiku.

Stopa smrtnosti broj je umrlih godišnje u odnosu na ukupno stanovništvo općine/grada. Podatke o broju umrlih i broju stanovnika osigurava Državni zavod za statistiku.

Domena: Pristup uslugama

Poddomena Socijalne usluge

Stopa upisa u vrtiće dobiveni je pokazatelj koji se izračunava podjelom broja djece upisane u vrtiće u svakoj općini/gradu s procijenjenim brojem djece vrtićke dobi. Broj djece u vrtićima pokazatelj je koji osigurava Državni zavod za statistiku. Opažanja se odnose na razdoblje upisa (na primjer, 2015./2016.), ali se vrijednosti pripisuju godini početka polaska u vrtić (na primjer, 2015.). Broj djece vrtićke dobi procjenjuje se na temelju njihova udjela u stanovništvu 2011. (podaci iz popisa stanovništva). Pretpostavlja se da je vrtićka dob u Hrvatskoj od 2. do 6. godine. Udio te kohorte u stanovništvu 2011. primjenjuje se na ukupan broj stanovnika procijenjen za svaku godinu (Državni zavod za statistiku) kako bi se dobio procijenjeni broj djece vrtićke dobi.

Udaljenost do doma zdravlja varijabla je koja pokazuje udaljenost do najbližeg doma zdravlja. Varijabla se kreira na temelju adresa domova zdravlja (podaci preuzeti od Hrvatskog zavoda za zdravstveno osiguranje). Udaljenosti se izračunavaju kao euklidska udaljenost centroida svake općine od poslovne zone ili doma zdravlja. Mjerna jedinica je metar.

Otvorenost proračuna jedinica lokalne samouprave ocjenjuje se indeksom otvorenosti proračuna koji izračunava Institut za javne financije. U indeksu se koriste vrijednosti od 0 do 5 koje označavaju broj ključnih dokumenata o proračunu koji se objavljuju na službenoj stranici općine/grada. Indeks je rezultat istraživačkog projekta „Razumijevanje, praćenje i analiziranje transparentnosti proračuna lokalnih jedinica: primjer Hrvatske i Slovenije – Indeks otvorenosti lokalnih proračuna (OLBI)” koji financira Hrvatska zaklada za znanost (IP-09-2014). Rezultati su objavljeni na <http://www.ijf.hr/hr/publikacije/casopisi/12/newsletter/110/proracunska-transparentnost-zupanija-gradova-i-opcina-studen-2015-8211-ozujak-2016/1158/> i <http://www.ijf.hr/upload/files/file/newsletter/97.pdf>. Trenutačno postoje usporediva opažanja za dvije godine. Podaci se prikupljaju na prelasku godine (2014./2015. i 2015./2016.), ali se vrijednosti pripisuju prvoj točki opažanja (tj. godinama 2014. i 2015.).

Poddomena Fizička infrastruktura

Udio kućanstava s pristupom javnoj vodoopskrbi izračunava se na temelju popisa stanovništva 2011. Projektni tim podatke uzima iz mikropodataka DZS-a prema popisu stanovništva (upitnik 2., informacije o kućanstvu i stanu, pitanje 9.)

Udio kućanstava s pristupom javnoj odvodnji izračunava se na temelju popisa stanovništva 2011. Projektni tim podatke uzima iz mikropodataka DZS-a prema popisu stanovništva (upitnik 2., informacije o kućanstvu i stanu, pitanje 9.)

Udio kućanstava s internetskim priključkom izračunava se na temelju popisa stanovništva 2011. Podatke tim dobiva iz mikropodataka DZS-a prema popisu stanovništva (upitnik 2., pitanje 4.)

Udio kućanstava bez centralnog grijanja izračunava se na temelju popisa stanovništva 2011. Podaci se dobivaju iz mikropodataka DZS-a prema popisu stanovništva (upitnik 2., informacije o kućanstvu i stanu, pitanje 10.)

Gustoća cestovne mreže odnosi se na gustoću cestovne mreže koja se izračunava podjelom dužine cesta (u kilometrima) s površinom općine (u kvadratnim kilometrima). Podaci o cestama odnose se na podatke za 2016. koje je tim dobio korištenjem OpenStreetMapa. Površina općine/grada dobivena je od Državnog zavoda za statistiku.

<i>Pokazatelj</i>	<i>Pozitivna/negativna korelacija</i>	
	<i>Veći pokazatelj, viša stopa siromaštva</i>	<i>Veći pokazatelj, niža stopa siromaštva</i>
1. <i>Stopa zaposlenosti</i>		-
2. <i>Stopa sudjelovanja</i>		-
3. <i>Stopa nezaposlenosti</i>	+	
4. <i>Udio umirovljenika u aktivnom stanovništvu</i>	+	
5. <i>Udio poreznih obveznika u stanovništvu</i>		-
6. <i>Prosječni oporezivi dohodak po stanovniku</i>		-
7. <i>Pribodi jedinica lokalne samouprave po stanovniku</i>		-
8. <i>Rashodi jedinica lokalne samouprave po stanovniku</i>		-
9. <i>Broj aktivnih poslovnih subjekata po stanovniku</i>		-
10. <i>Broj aktivnih obrta po stanovniku</i>		-
11. <i>Udio zaposlenih u poljoprivredi</i>		-
12. <i>Neto dohodak stanovništva po stanovniku</i>		-
13. <i>Broj registriranih osobnih automobila po stanovniku</i>		-

14. <i>Udio korisnika ZMN-a u ukupnom stanovništvu</i>	+	
15. <i>Prosječni ZMN po stanovniku</i>	+	
16. <i>Doplatak za djecu po stanovniku</i>	+	
17. <i>Udio osoba sa srednjoškolskim ili višim obrazovanjem u radno sposobnom stanovništvu</i>		-
18. <i>Udio osoba koje koriste pomoć druge osobe pri obavljanju svakodnevnih aktivnosti</i>	+	
19. <i>Udio učenika koji nisu položili maturu</i>	+	
20. <i>Kretanje stanovništva</i>		-
21. <i>Stopa ekonomske ovisnosti</i>	+	
22. <i>Gustoća stanovništva</i>		-
23. <i>Stopa smrtnosti</i>	+	
24. <i>Stopa upisa u vrtiće</i>		-
25. <i>Udaljenost do doma zdravlja</i>	+	
26. <i>Otvorenost proračuna jedinica lokalne samouprave</i>		-
27. <i>Udio kućanstava s pristupom javnoj vodoopskrbi</i>		-
28. <i>Udio kućanstava s pristupom javnoj odvodnji</i>		-
29. <i>Udio kućanstava s internetskim priključkom</i>		-
30. <i>Udio kućanstava bez centralnog grijanja</i>		-
31. <i>Gustoća cestovne mreže</i>		-

Za više informacija o fondovima EU-a posjetite www.strukturnifondovi.hr i www.razvoj.gov.hr.

Sadržaj ovog izvješća isključiva je odgovornost Svjetske banke.