



doi:10.5559/di.23.2.01

MULTIVARIJATNA KLASIFIKACIJA JEDINICA LOKALNE I REGIONALNE SAMOUPRAVE PREMA SOCIOEKONOMSKOJ RAZVIJENOSTI

Ana PERIŠIĆ
Veleučilište u Šibeniku, Šibenik

UDK: 316.334.2(497.5):352/353
Prethodno priopćenje

Primljeno: 27. 7. 2013.

Problem nejednakoga regionalnog razvoja jedan je od ključnih problema hrvatske ekonomske politike. Zakonom o regionalnom razvoju Republike Hrvatske uređeno je ocjenjivanje i razvrstavanje jedinica lokalne i regionalne samouprave prema razvijenosti, koja se temelji na indeksu razvijenosti. Ova univarijantna klasifikacija počiva na vrijednosti samo jedne varijable, koja je linearna kombinacija standardiziranih vrijednosti pokazatelja, što uzrokuje gubitak informacija. Cilj je ovoga rada prikazati alternativni pristup ocjenjivanju i kategorizaciji teritorijalnih jedinica prema socioekonomskoj razvijenosti na temelju multivarijantne analize. U radu je predložena klasifikacija jedinica lokalne i regionalne samouprave dobivena primjenom multivarijantnih metoda na temelju pet socioekonomskih pokazatelja. Poseban naglasak stavljen je na područja koja zaostaju u razvoju. Uočeni su i otklonjeni problemi multikolinearnosti i problemi postojanja izdvojenica koji su prisutni u klasifikaciji na temelju indeksa razvijenosti. Rezultati analiza upućuju na postojanje velikih razlika u regionalnoj razvijenosti. Gotovo sve metode klasterne analize rezultiraju posebnim klasterom u kojem su izdvojene jedinice koje imaju izražen problem depopulacije, ali ne i ekonomske nerazvijenosti, što omogućuje da se jedinice obuhvate posebnim mjerama poticanja demografskoga razvitka.

Ključne riječi: multivarijantna analiza, regionalne nejednakosti, klasifikacija, socioekonomska razvijenost, indeks razvijenosti

✉ Ana Perišić, Veleučilište u Šibeniku, Trg Andrije Hebranga 11,
22 000 Šibenik, Hrvatska.
E-mail: sisak@vus.hr

UVOD

Republika Hrvatska, površinom i brojem stanovnika mala zemlja, ističe se regionalnim razlikama. Iako su različitosti hrvatskih regija bogatstvo za državu, one su i problem u nejednakom regionalnom razvoju. Osim prirodno-geografskih i socioekonomskih razlika, velike su razlike i u regionalnoj razvijenosti. Mnogi su uzroci regionalnih nejednakosti. One mogu biti rezultat zemljopisne udaljenosti, društvenih i ekonomskih promjena ili kombinacija tih činitelja. Učinak tih nedostataka ogleda se u društvenom osiromašenju, lošoj kvaliteti škola, visokoj stopi nezaposlenosti te neadekvatnoj infrastrukturi (Kesner Škreb, 2009, str. 103-105). Problem izrazite depulacije nerazvijenih područja, različita obrazovna struktura i različit stupanj ekonomske razvijenosti vidi se na županjskoj, a posebno na lokalnoj razini. Uz problem visokoga stupnja nezaposlenosti i gašenja gospodarskih aktivnosti, problem niskog udjela obrazovanoga stanovništva te odljev mladoga i obrazovanoga stanovništva ne otvara nove prilike za razvoj nerazvijenih područja. Loša socioekonomska situacija rezultira slabim fiskalnim kapacitetima jedinica i čini ih ovisnima o državnim dotacijama. Često kritiziran velik broj jedinica lokalne i regionalne samouprave zahtijeva njihovu kategorizaciju za potrebe provedbe regionalnih politika.¹ Kako je problem zaostajanja regija u razvoju jedan od ključnih problema hrvatske politike, ali i politike Europske unije, posebno je važna kategorizacija područja koja zaostaju i u ekonomskom i demografskom razvoju.

Temelj izgradnje sustava vođenja regionalne politike Republike Hrvatske postavlja se donošenjem Zakona o regionalnom razvoju potkraj 2009. godine (Zakon o regionalnom razvoju Republike Hrvatske, *Narodne novine*, 153/09). Tim se zakonom uređuju ciljevi i načela upravljanja regionalnim razvojem Republike Hrvatske, planski dokumenti, tijela nadležna za upravljanje regionalnim razvojem, ocjenjivanje stupnja razvijenosti jedinica lokalne i područne (regionalne) samouprave i izvještavanje o provedbi regionalne razvojne politike. Posebna novina jest uvođenje indeksa razvijenosti i ocjenjivanje stupnja razvijenosti jedinica područne samouprave, a ne samo jedinica lokalne samouprave. Indeks razvijenosti je kompozitni pokazatelj koji se računa kao ponderirani prosjek više osnovnih društveno-gospodarskih pokazatelja za mjerenje stupnja razvijenosti jedinica lokalne i područne (regionalne) samouprave (Zakon o regionalnom razvoju, 2009). Indeks razvijenosti računa se na temelju pet socioekonomskih pokazatelja. To su: stopa nezaposlenosti, dohodak po stanovniku, proračunski prihodi jedinica lokalne, odnosno područne samouprave po stanovniku, opće kretanje stanovništva i stopa obrazovanosti. Vrijednost indeksa izračunava se kao ponderi-

rani prosjek odstupanja standardiziranih vrijednosti socioekonomskih pokazatelja od prosjeka Republike Hrvatske, gdje je udio stope nezaposlenosti najveći i iznosi 30%, slijedi udio dohotka po stanovniku sa 25%, dok proračunski prihodi jedinica lokalne, odnosno područne samouprave po stanovniku, opće kretanje stanovništva i stopa obrazovanosti imaju udjele od 15%. Ocjenjivanje stupnja razvijenosti provodi se svake tri godine. Na temelju indeksa razvijenosti definirana su potpomognuta područja Republike Hrvatske, odnosno područja koja prema stupnju razvijenosti zaostaju za nacionalnim prosjekom i čiji razvoj treba dodatno poticati.² U Strategiji regionalnoga razvoja Republike Hrvatske određene su mjere za razvoj potpomognutih područja: mjere namijenjene gospodarskim subjektima, mjere namijenjene stanovništvu i mjere za jačanje fiskalnih kapaciteta jedinica lokalne i područne samouprave.³ Predviđa se i izradba posebnih razvojnih programa za potpomognuta područja: program demografske obnove, program jačanja obrazovnih kapaciteta, program privlačenja investitora i program razvoja regionalnih klastera.

Donošenje novoga Zakona o regionalnom razvoju očekuje se u prvom tromjesečju 2014. U Ministarstvu regionalnog razvoja i fondova Europske unije naglašeno je kako će novim Zakonom o regionalnom razvoju Republike Hrvatske biti riješen višegodišnji problem paralelnog egzistiranja raznih kategorija slabije razvijenih područja i uveden jedinstveni sustav primjenjiv na cijelo područje Republike Hrvatske. Neke od glavnih novina koje donosi novi zakon jesu uvođenje kategorije urbanoga područja (i dodatno među njima aglomeracijskih središta), osnivanje Savjeta za regionalni razvoj i veživanje svih mjera poticanja razvoja u budućnosti za indeks razvijenosti kao temeljni instrument utvrđivanja stupnja razvijenosti svih jedinica lokalne i područne (regionalne) samouprave u Republici Hrvatskoj.⁴

METODOLOGIJA ISTRAŽIVANJA

Cilj je ovoga rada prikazati alternativni pristup ocjenjivanju i kategorizaciji teritorijalnih jedinica prema socioekonomskoj razvijenosti. Pristup se temelji na multivarijantnoj analizi socioekonomskih obilježja jedinica lokalne i područne samouprave. Ispitane su pretpostavke za primjenu metoda multivarijantne analize. Grafičkom metodom i statističkim testovima ispitana je normalnost varijabli. Postojanje izdvojenica ispitano je grafom Mahalanobisovih udaljenosti. Na temelju korelacijske analize proučena je veza između varijabli, odnosno pokazatelja socioekonomskoga razvoja, a faktorom inflacije varijance ispitano je postojanje multikolinearnosti. Analizirana je klasifikacija na temelju indeksa razvijenosti. Provedena je multivarijantna analiza nad pet socioekonomskih pokazatelja

jedinica lokalne samouprave te četiri i pet socioekonomskih pokazatelja jedinica regionalne samouprave. Jedinice su metodama hijerarhijske i nehijerarhijske klusterske analize svrstane u homogene skupine s visokim stupnjem heterogenosti između grupa. Provedena je klusterska analiza na temelju više hijerarhijskih metoda (metode najbližega i najdaljega susjeda, centroidna metoda, metoda prosječne udaljenosti i Wardova metoda) i na temelju nehijerarhijske klusterske analize (odabrana je *K-means* metoda), gdje je hijerarhijskom klusterskom analizom utvrđen optimalan broj klastera te je na rezultatima hijerarhijske analize provedena nehijerarhijska klusterska analiza. Radi profilacije klastera jedinica lokalne samouprave provedena je kvadratna diskriminacijska analiza. Diskriminacijska analiza provedena je i na osnovi rezultata klasifikacije jedinica lokalne samouprave koja se temelji na indeksu razvijenosti. Diskriminacijska analiza upotrijebljena je samo radi profilacije klastera zbog odstupanja od multivarijatne normalnosti varijabli. Odstupanja od pretpostavke normalnosti varijabli uglavnom nisu "fatalna", što znači da su rezultati testova i dalje pouzdani (Statsoft, 2012).

Multivarijatnu klasifikaciju kao moguću metodu regionalizacije Republike Hrvatske prikazali su Rimac, Rihtar i Oliveira-Roca (1992), Cziráky, Sambt, Rován i Puljiz (2005), Lovrinčević, Marić i Rajh (2005), Rašić-Bakarić (2006, 2012), Kurnoga Živadinović (2007), Jurun i Pivac (2010). Autori primjenjuju metode faktorske, diskriminacijske i klusterske analize nad većim brojem socioekonomskih i demografskih obilježja lokalnih, odnosno regionalnih, jedinica Republike Hrvatske, radi svrstavanja jedinica u homogene grupe s obzirom na obilježja društvenoga i gospodarskoga razvoja.

PODACI I PRETPOSTAVKE ZA PRIMJENU METODA MULTIVARIJATNE ANALIZE

Kako je cilj rada prikazati alternativni način kategorizacije jedinica lokalne i područne samouprave, odabrani su isti socioekonomski pokazatelji upotrijebljeni za izračun indeksa razvijenosti. U Tablici 1 dane su prosječne vrijednosti i pripadni koeficijenti varijacije socioekonomskih pokazatelja te usporedba najmanjih i najvećih vrijednosti pokazatelja jedinica lokalne i regionalne samouprave. Podaci u tablici upućuju na postojanje velikih regionalnih nejednakosti. Usporedbom BDP-a po stanovniku po županijama također se može upozoriti na nejednak regionalni razvoj u Republici Hrvatskoj. Od 2006. do 2008. godine BDP po stanovniku bio je najviši u gradu Zagrebu i bio je triput viši od BDP-a po stanovniku u Brodsko-posavskoj županiji, županiji s najnižom vrijednosti BDP-a po stanovniku.⁵

	Prosječan		Prosječni		Prosječna		Kretanje		Udio	
	dohodak po		izvorni		stopa		stanovništva		obrazovanih	
	stanovniku		prihodi po		nezaposlenosti		(2001.–1991.)		u stanovništvu	
	(2006.–2008.)		(2006.–2008.)		(2006.–2008.)				16–65 godina	
	JLS	JRS	JLS	JRS	JLS	JRS	JLS	JRS	JLS	JRS
Prosjek	19647	23368	2132	2828	16,72%	15,30%	93	91,78	55,20%	63,12%
Koeficijent varijacije	329%	23%	80%	53%	174%	36%	488%	1234%	423%	14%
Min	7267	16963	156	1290	1,40%	5,90%	9,4	65,1	15,30%	49,40%
Max	39687	39687	42379	6939	69,60%	23,60%	188,7	110,6	85%	80,30%

Izvor: Ministarstvo regionalnog razvoja i fondova Europske unije (2010a i 2010b).

TABLICA 1
Usporedba prosječnih vrijednosti pokazatelja, koeficijenta varijacije te minimalnih i maksimalnih vrijednosti pokazatelja lokalnih jedinica

Zbog postojanja multikolinearnosti pokazatelja razvijenosti na županijskoj razini bilo je potrebno jedan pokazatelj izostaviti ili zamijeniti. Tako su na lokalnoj i županijskoj razini uzeti sljedeći pokazatelji: prosječna stopa nezaposlenosti, prosječan dohodak po stanovniku, kretanje stanovništva, udio obrazovanoga stanovništva u stanovništvu od 16 do 65 godina i prosječni izvorni prihodi po stanovniku. Na županijskoj razini uzeti su i pokazatelji: udio pomoći u ukupnim приходима te udio izvornih prihoda u ukupnim rashodima. Podaci su na godišnjoj razini te je analizirano razdoblje od 2006. do 2008. godine. Podaci su preuzeti od Državnog zavoda za statistiku, Ministarstva financija i Ministarstva regionalnog razvoja i fondova Europske unije.

TABLICA 2
Koeficijenti korelacije socioekonomskih pokazatelja jedinica lokalne samouprave

Provedena je korelacijska analiza socioekonomskih pokazatelja jedinica lokalne samouprave. Najveći koeficijent korelacije uočen je između varijabli prosječan dohodak po stanovniku i udio obrazovanoga stanovništva (0,718). Socioekonomski pokazatelji – dohodak po stanovniku, prosječni izvorni prihodi po stanovniku, kretanje stanovništva i udio obrazovanoga stanovništva – pozitivno su korelirani, dok je prosječna stopa nezaposlenosti negativno korelirana s ostalim pokazateljima. Demografski pokazatelj kretanje stanovništva najslabije je koreliran s ostalim pokazateljima.


	1	2	3	4	5
1 Prosječan dohodak po stanovniku	1,000				
2 Prosječni izvorni prihodi po stanovniku	0,454	1,000			
3 Prosječna stopa nezaposlenosti	-0,629	-0,345	1,000		
4 Kretanje stanovništva	0,151	0,253	-0,425	1,000	
5 Udio obrazovanoga stanovništva	0,718	0,423	-0,468	0,386	1,000

Normalnost varijabli ispitana je uz pomoć *QQ-plota* i Shapiro-Wilksova testa. Rezultati pokazuju da socioekonomski pokazatelji jedinica lokalne samouprave nisu normalno dis-

tribuirani.⁶ Testirane su i hipoteze o normalnoj distribuirano-
sti socioekonomskih pokazatelja jedinica regionalne samouprave. Hipoteze o normalnosti pokazatelja: prosječan dohodak po stanovniku, prosječni izvorni prihodi po stanovniku i kretanje stanovništva odbacuju se (vrijednosti Shapiro-Wilksove testne statistike W manje su od 0,92, a pripadne p -vrijednosti manje su od 0,09), dok se hipoteze o normalnosti pokazatelja prosječna stopa nezaposlenosti ($W = 0,94$, $p = 0,31$) i udio obrazovanoga stanovništva ($W = 0,96$, $p = 0,53$) ne mogu odbaciti. Budući da je nužan uvjet multivarijatne normalnosti univarijatna normalnost svake od varijabli, ne može se zaključiti da su socioekonomski pokazatelji jedinica lokalne, odnosno regionalne, samouprave multivarijatno normalno distribuirani, što postavlja ograničenja u primjeni nekih multivarijatnih tehnika kao što su MANOVA, faktorska analiza i diskriminacijska analiza.

U skupu jedinica lokalne samouprave ispitano je postojanje izdvojenica. Provedena je analiza izdvojenica temeljena na kvadriranoj Mahalanobisovoj udaljenosti. Podaci s velikom Mahalanobisovom udaljenosti ocijenjeni su kao izdvojenice (Ben Gal, 2005). Na Grafikonu 1 vidi se kako se odvaja jedna ozbiljna izdvojenica (gornji desni kut grafa). Radi se o općini Dugopolje. Ovakav rezultat potvrdit će i klasteraska analiza, stoga će biti provedena i klasteraska analiza bez općine Dugopolje.

➤ GRAFIKON 1
Analiza izdvojenica
(graf kvadriranih
Mahalanobisovih
udaljenosti)



● TABLICA 3
Koefficienti korelacije
socioekonomskih
pokazatelja županija

Prije provođenja klasterске analize jedinica regionalne samouprave ispitano je postojanje multikolinearnosti pokazatelja. U Tablici 3 dani su koefficienti korelacije pokazatelja.

	1	2	3	4	5
1 Prosječan dohodak po stanovniku	1,00				
2 Prosječni izvorni prihodi po stanovniku	0,93	1,00			
3 Prosječna stopa nezaposlenosti	-0,68	-0,65	1,00		
4 Kretanje stanovništva	0,21	0,24	-0,47	1,00	
5 Udio obrazovanoga stanovništva	0,79	0,82	-0,49	0,16	1,00

Uočen je visok stupanj koreliranosti odabranih socioekonomskih pokazatelja županija. Najveći stupanj korelacije uočen je između varijabli prosječni izvorni prihodi po stanovniku i prosječni dohodak po stanovniku, čak 0,93. Pokazatelj kretanje stanovništva najslabije je koreliran s ostalim varijablama. U kontekstu klsterske analize, visoka koreliranost varijabli postoji ako je koeficijent korelacije veći od 0,5, a niska koreliranost ako je koeficijent korelacije manji od 0,2 (Sambandam, 2003). Koeficijenti korelacije iznad 0,9 uvijek su problematični (Mooi i Sarstedt, 2011, str. 242).⁷ Postojanje multikolinearnosti ispitano je uz pomoć faktora inflacije varijance. Budući da je faktor inflacije varijance veći od pet, dobiveni rezultati upućuju na postojanje multikolinearnosti (Bahovec i Erjavec, 2009, str. 164-165). Problem multikolinearnosti riješen je izostavljanjem varijable prosječni izvorni prihodi po stanovniku iz analize, odnosno zamjenom toga pokazatelja alternativnim pokazateljima financijske snage županijskih proračuna: udio izvornih prihoda u ukupnim rashodima i udio pomoći u ukupnim приходima.

Zbog velikih razlika u vrijednostima i standardnim devijacijama varijabli i napose zbog razlike u mjernim jedinicama varijabli (varijable prosječan dohodak po stanovniku i prosječni izvorni prihodi po stanovniku izražene su u kunama po stanovniku, dok su varijable udio pomoći u ukupnim приходima, udio izvornih prihoda u ukupnim rashodima, prosječna stopa nezaposlenosti i udio obrazovanoga stanovništva izražene relativno), poželjno je standardizirati varijable (Hair, Anderson, Tatham i Black, 1995, str. 434-435). Stoga su za potrebe klsterske analize varijable standardizirane.

KLASIFIKACIJA UTEMELJENA NA INDEKSU RAZVIJENOSTI

Odlukom Vlade,⁸ jedinice regionalne samouprave prema indeksu razvijenosti razvrstavaju se u četiri skupine: prvu skupinu čine županije čija je vrijednost indeksa razvijenosti manja od 75% prosjeka Republike Hrvatske (Bjelovarsko-bilogorska županija, Brodsko-posavska županija, Karlovačka županija, Koprivničko-križevačka županija, Ličko-senjska županija, Osječko-baranjska županija, Požeško-slavonska županija, Sisačko-moslavačka županija, Šibensko-kninska županija, Virovitičko-podravska županija i Vukovarsko-srijemska županija). Drugu skupinu čine jedinice područne samouprave čija je vrijednost indeksa razvijenosti između 75% i 100% prosjeka Republike Hrvatske: Krapinsko-zagorska županija, Međimurska županija, Splitsko-dalmatinska županija, Varaždinska županija i Zadarska županija. Treća skupina sastoji se od županija čija je vrijednost indeksa razvijenosti između 100% i 125% prosjeka Republike Hrvatske: Dubrovačko-neretvanska

županija i Zagrebačka županija, dok se u četvrtoj skupini nalaze jedinice čija je vrijednost indeksa razvijenosti veća od 125% prosjeka Republike Hrvatske: Grad Zagreb, Istarska županija i Primorsko-goranska županija.

Jedinice lokalne samouprave razvrstavaju se prema indeksu razvijenosti u pet skupina: prvu skupinu čine jedinice lokalne samouprave čija je vrijednost indeksa razvijenosti manja od 50% prosjeka Republike Hrvatske, drugu skupinu čine jedinice lokalne samouprave čija je vrijednost indeksa razvijenosti između 50% i 75% prosjeka Republike Hrvatske, treću čine jedinice čija je vrijednost indeksa razvijenosti između 75% i 100% prosjeka Republike Hrvatske, četvrtu skupinu čine jedinice lokalne samouprave čija je vrijednost indeksa razvijenosti između 100% i 125% prosjeka Republike Hrvatske, dok se peta skupina sastoji od jedinica lokalne samouprave čija je vrijednost indeksa razvijenosti veća od 125% prosjeka Republike Hrvatske.

Status potpomognutoga područja stječe jedinica područne (regionalne) samouprave razvrstana u prvu skupinu te jedinica lokalne samouprave razvrstana u prvu ili drugu skupinu. Mjere posebnoga poticanja regulirane su posebnim zakonom.

Ukupno jedanaest županija i 256 lokalnih jedinica imaju status potpomognutoga područja. Riječ je o više od polovice županija (52%) i gotovo svakoj drugoj lokalnoj jedinici (46%). Više od 80% jedinica s područja Bjelovarsko-bilogorske županije, Brodsko-posavske, Virovitičko-podravske i Vukovarsko-srijemske županije klasificirano je u skupinu jedinica lokalne samouprave koje zaostaju u razvoju. Također, u skupinu jedinica koje zaostaju u razvoju svrstano je više od polovice jedinica lokalne samouprave s područja Karlovačke, Koprivničko-križevačke, Ličko-senjske, Međimurske, Osječko-baranjske, Požeško-slavonske i Sisačko-moslavačke županije. Tri četvrtine jedinica najrazvijenije skupine čine jedinice lokalne samouprave s područja Primorsko-goranske i Istarske županije, a uz Grad Zagreb tu su još i po jedna jedinica s područja Zagrebačke, Krapinsko-zagorske i Ličko-senjske županije te 4 jedinice iz Splitsko-dalmatinske županije.

Prednosti ovakve klasifikacije jesu jednostavnost postupka klasifikacije, odnosno izračuna indeksa razvijenosti, koji ne zahtijeva poznavanje sofisticiranih statističkih znanja. Jedna od prednosti jest mogućnost rangiranja jedinica lokalne i regionalne samouprave prema razvijenosti, što omogućuje lakšu međusobnu usporedbu jedinica.

Najveći nedostatak ovakve klasifikacije jedinica lokalne i regionalne samouprave jest u tome što se klasifikacija temelji na vrijednosti jedne varijable, što uzrokuje gubitak informacija i dolaženje do krivih zaključaka, tj. pogrešnoga klasifici-

ranja jedinice. Pri izračunu indeksa razvijenosti problem nastaje kod ekstremno velikih ili ekstremno malih vrijednosti varijabli. Kako je indeks razvijenosti linearna kombinacija više pokazatelja, ekstremno velika ili ekstremno mala vrijednost jednog od pokazatelja može vrijednost samog indeksa odvesti u krivom smjeru.

Drugi nedostatak ovakve klasifikacije jest u tome što nije analizirana prisutnost izdvojenica kao što je, na primjer, općina Dugopolje, koja ima ekstremno visoke izvorne prihode po stanovniku od 42 379 kn po stanovniku. Usporedbe radi, općina koja je slijedi po veličini prosječnih izvornih prihoda po stanovniku i prema veličini indeksa razvijenosti jest općina Kostrena s tripud manjim prosječnim izvornim приходima od 13 139 kn po stanovniku. Razlika od prosjeka svih ostalih općina višestruko je veća: općina Dugopolje ima čak dvadeset puta veće izvorne prihode po stanovniku od prosjeka ostalih jedinica lokalne samouprave.

Dalje, ovakav pristup klasifikaciji jedinica lokalne samouprave ne vodi računa o koreliranosti pokazatelja. Visok stupanj korelacije pokazatelja znači da oba pokazatelja mjere vrlo slične fenomene, odnosno da je informativna vrijednost jednoga pokazatelja u odnosu na drugi vrlo mala (Puljiz, Maleković, Polić i Jurlin, 2005). Nedostatak klasifikacije jedinica područne samouprave jest multikolinearnost pokazatelja. Stoga je poželjno izostaviti jedan pokazatelj ili ga zamijeniti drugim.

MULTIVARIJATNA KLASIFIKACIJA JEDINICA LOKALNE SAMOUPRAVE

Diskriminacijska analiza poslužila je profilaciji rezultata dobivenih kategorizacijom jedinica lokalne samouprave na temelju indeksa razvijenosti. Zbog nejednakih kovarijacijskih matrica između grupa, primijenjena je kvadratna diskriminacijska analiza (Timm, 2002, str. 439). Kako su varijable prosječan dohodak po stanovniku, prosječni izvorni prihodi po stanovniku, prosječna stopa nezaposlenosti, kretanje stanovništva i udio obrazovanoga stanovništva izražene u različitim mjernim jedinicama, uočene su velike razlike u njihovim prosječnim vrijednostima, odnosno standardnim devijacijama te je zbog koreliranosti varijabli odabrana Mahalanobisova udaljenost za računanje udaljenosti objekata od centroida grupa. Doprinos pojedine varijable diskriminaciji grupa mjeren je na temelju F-vrijednosti. Varijabla koja najviše pridonosi diskriminaciji jest varijabla prosječan dohodak po stanovniku (s pripadnom F-vrijednosti 272,75), dok je varijabla koja najmanje pridonosi diskriminaciji između grupa kretanje stanovništva (s pripadnom F-vrijednosti 37,37). Dakle, ekonomski pokazatelji znatno više utječu na diskriminaciju između grupa od demografskih pokazatelja. Ovakav je rezultat očeki-

● **TABLICA 4**
Prosječne vrijednosti
socioekonomskih
pokazatelja JLS i
pripadajućih koefi-
cijenata varijacije za 6-
klastersko rješenje
dobiveno *K-means*
metodom s centrima
dobivenim Wardovom
metodom

van, jer ekonomski pokazatelji imaju veće ili jednake pondere od demografskih pri izračunu indeksa razvijenosti.

Rezultati hijerarhijskih klusterskih analiza i nehijerarhijske klusterske analize (s unaprijed određenim brojem od pet klastera) kao rješenje daju jednočlan klaster.⁹ Tako rezultati klusterske analize potvrđuju postojanje izdvojenica. Riječ je o općini Dugopolje, koja je isključena iz daljnje analize. Hijerarhijskim metodama izdvajaju se rješenja sa 5, 6 i 8 klastera te je provedena nehijerarhijska klusterska analiza. Najbolje interpretabilno rješenje dobiveno je *K-means* metodom s unaprijed određenim brojem od 6 klastera te zadanim centroidima klastera dobivenim na temelju Wardove metode.

U Tablici 4 dane su prosječne vrijednosti socioekonomskih pokazatelja po klasterima i pripadni koeficijenti varijacije koji su dani u zagradama. Također je u Tablici 4 za svaki klaster dana i najveća udaljenost objekata u klasteru od centroida klastera i veličina klastera (n) mjerena brojem jedinica lokalne samouprave.

Klaster	Prosječan dohodak po stanovniku	Prosječni izvorni prihodi po stanovniku	Prosječna stopa nezaposlenosti	Kretanje stanovništva	Udio obrazovanoga stanovništva	Najveća udaljenost	n
1	14280,88 (23,64%)	639,08 (41,75%)	42% (22,27%)	57,45 (29,92%)	43% (23,07%)	3,49	26
2	21233,64 (16,05%)	1410,72 (53,67%)	18% (33,83%)	62,70 (20,08%)	53% (16,37%)	2,53	53
3	18480,32 (15,17%)	1380,07 (57,07%)	14% (36,48%)	98,77 (13,97%)	55% (12,89%)	5,09	168
4	25140,12 (14,87%)	2712,06 (36,74%)	10% (42,60%)	102,40 (14,09%)	67% (10,67%)	4,77	126
5	27831,86 (17,82%)	7202,84 (27,37%)	8% (52,75%)	105,22 (14,19%)	71% (12,57%)	3,94	51
6	13068,11 (16,73%)	843,67 (90,90%)	24% (27,90%)	91,07 (9,83%)	41% (19,40%)	3,27	131
Prosjek lokalnih jedinica	19646,8 (30%)	2026,35 ¹⁰ (98%)	17% (57%)	93 (20%)	55% (24%)	-	-

Prvi klaster izdvaja se kao klaster najnižega stupnja razvijenosti. Prosječne vrijednosti svih socioekonomskih pokazatelja lošije su od prosjeka svih jedinica lokalne samouprave, a ujedno su i prosječne vrijednosti pokazatelja prosječni izvorni prihodi po stanovniku i kretanje stanovništva najniže među klasterima, dok je prosječna stopa nezaposlenosti najviša. Sve jedinice svrstane u ovaj klaster bilježe ispodprosječne vrijednosti prosječnoga dohotka po stanovniku, prosječnih izvornih prihoda po stanovniku i iznadprosječne vrijednosti prosječne stope nezaposlenosti. Prvi klaster obuhvaća najmanji

broj stanovništva Republike Hrvatske, tek oko 2%. Jedinice svrstane u ovaj klaster nalaze se na prostoru Središnje i Istočne te Jadranske Hrvatske, gdje se više od tri četvrtine jedinica prvoga klastera nalazi na prostoru Središnje i Istočne Hrvatske.¹¹

Drugi klaster sastoji se od jedinica lokalne samouprave koje bilježe ozbiljan problem depopulacije. Vrijednost pokazatelja kretanje stanovništva manja je od 0,83 za sve jedinice. Prosječne vrijednosti ostalih socioekonomskih pokazatelja uglavnom se kreću oko prosjeka svih lokalnih jedinica. Jedinice svrstane u ovaj klaster nalaze se na prostoru Središnje i Istočne te Jadranske Hrvatske, pri čemu su najbrojnije jedinice s područja Zadarske, Karlovačke, Šibensko-kninske, Ličko-senjske i Splitsko-dalmatinske županije. Drugi klaster obuhvaća oko 6% stanovništva Republike Hrvatske. U ovome je klasteru 19 jedinica lokalne samouprave s izraženim problemom depopulacije, koje su prema indeksu razvijenosti ocijenjene kao jedinice srednjeg stupnja razvijenosti.¹²

Treći je klaster brojem lokalnih jedinica najveći klaster te je ujedno i klaster s najvećim stupnjem heterogenosti. Prosječne vrijednosti socioekonomskih pokazatelja kreću se oko prosjeka svih lokalnih jedinica, pa se ovaj klaster može okarakterizirati kao klaster srednjega stupnja razvijenosti. Najveći se broj jedinica u ovom klasteru nalazi na prostoru Sjeverozapadne Hrvatske, a u njemu živi oko 21% stanovništva Republike Hrvatske.

Četvrti klaster bilježi iznadprosječne vrijednosti svih pokazatelja, osim prosječne stope nezaposlenosti, koja je ispod prosjeka svih jedinica lokalne samouprave, pa se četvrti klaster može opisati kao klaster srednje visokoga stupnja razvijenosti. Najveći se broj jedinica u ovom klasteru nalazi na prostoru Jadranske Hrvatske. Zanimljivo je kako se u ovome klasteru nalazi većina regionalnih središta Hrvatske: Bjelovar, Kutina, Koprivnica, Požega, Krapina, Pazin, Čakovec, Sisak, Karlovac, Osijek, Šibenik, Zadar, Rijeka, Varaždin, Dubrovnik i Split. To je i jedan od razloga što je ovim klasterom obuhvaćen najveći broj stanovnika, oko 37% stanovništva Hrvatske.

Peti klaster izdvaja se kao leaderski klaster. Prosječne vrijednosti pokazatelja prosječan dohodak po stanovniku, prosječni izvorni prihodi po stanovniku, kretanje stanovništva i udio obrazovanoga stanovništva najviše su, dok je prosječna stopa nezaposlenosti najniža među klasterima. Više od 70% jedinica ovoga klastera čine jedinice s područja Primorsko-goranske i Istarske županije. Zanimljivo je kako u ovome klasteru nema ni jedne jedinice lokalne samouprave s područja Središnje i Istočne Hrvatske. Od velikih gradova u ovaj klaster svrstani su samo Grad Zagreb i Pula. Peti klaster obuhvaća oko 23% stanovništva Republike Hrvatske, gdje stanovništvo Grada Zagreba čini više od 70% stanovništva klastera.

Šesti klaster sastoji se od jedinica lokalne samouprave koje zaostaju u razvoju. Prosječne vrijednosti pokazatelja udio obrazovanoga stanovništva i prosječan dohodak po stanovniku najniže su među svim klasterima. Čak 95% jedinica lokalne samouprave ima ispodprosječne izvorne prihode po stanovniku, a više od 80% jedinica bilježi iznadprosječnu stopu nezaposlenosti, dok 90% jedinica bilježi negativno kretanje stanovništva. Više od dvije trećine jedinica lokalne samouprave ovoga klastera nalazi se na prostoru Središnje i Istočne Hrvatske. U ovome je klasteru i 20% jedinica lokalne samouprave s područja Sjeverozapadne Hrvatske, to su ujedno i jedine jedinice s toga područja svrstane u klaster koji zaostaje u razvoju. Šesti klaster obuhvaća oko 11% stanovništva Republike Hrvatske.

U klasteru koji zaostaju u razvoju ukupno je svrstano 210 jedinica lokalne samouprave. Više od polovice jedinica klastera koji zaostaju u razvoju jest s područja Brodsko-posavske, Karlovačke, Koprivničko-križevačke, Osječko-baranjske, Sisačko-moslavačke i Šibensko-kninske županije te više od tri četvrtine jedinica lokalne samouprave s područja Bjelovarsko-bilogorske, Ličko-senjske, Virovitičko-podravske i Vukovarsko-srijemske županije.

K-means metodama s različitim brojem klastera (5, 6 i 8-klastersko rješenje) dobivaju se približno jednaki rezultati. Sve metode svrstavaju ukupno 178 istih jedinica lokalne samouprave u klasteru koji zaostaju u razvoju, tj. podudaraju se u najmanje 80% jedinica. Sve metode, uz klasteru koji značajno zaostaju u razvoju, u poseban klaster grupiraju jedinice lokalne samouprave koje nemaju značajno loše vrijednosti ekonomskih pokazatelja, ali imaju ozbiljan problem depopulacije i trebaju biti obuhvaćene mjerama namijenjenim područjima koja zaostaju u razvoju. Ovakav rezultat mogao se očekivati, jer pokazatelj kretanje stanovništva nije koreliran s ostalim socioekonomskim pokazateljima. Izdvojen je i klaster s najnižim prosječnim vrijednostima varijabli udio obrazovanoga stanovništva i prosječan dohodak po stanovniku, što je također u skladu s koreliranosti istih pokazatelja. Prosječne vrijednosti pokazatelja skupina dobivenih na temelju indeksa razvijenosti slijede gradacijski, što nije u skladu s koreliranosti, odnosno nekoreliranosti, pokazatelja.

U Tablici 5 dana je usporedba klasifikacije jedinica lokalne samouprave koje zaostaju u razvoju dobivene na temelju indeksa razvijenosti i klusterskih metoda prema pripadnosti županijama. Najveća razlika može se uočiti u broju klasificiranih jedinica s područja Međimurske županije. Dok je prema indeksu razvijenosti čak 56% jedinica svrstano u skupinu koja zaostaje u razvoju, prema 6 i 8-klasterskom rješenju u klasteru koji zaostaju u razvoju svrstano ih je 8%.¹³

Županije	Prema indeksu razvijenosti	8-klastersko rješenje <i>K-means</i> metode centri automatski	6-klastersko rješenje centri dobiveni Wardovom metodom
Bjelovarsko-bilogorska	91,30	78,26	78,26
Brodsko-posavska	85,71	67,86	67,86
Dubrovačko-neretvanska	18,18	0,00	9,09
Grad Zagreb	0,00	0,00	0,00
Istarska	0,00	0,00	2,44
Karlovačka	77,27	59,09	59,09
Koprivničko-križevačka	76,00	60,00	60,00
Krapinsko-zagorska	18,75	0,00	0,00
Ličko-senjska	50,00	66,67	75,00
Međimurska	56,00	8,00	8,00
Osječko-baranjska	73,81	64,29	66,67
Požeško-slavonska	70,00	70,00	70,00
Primorsko-goranska	0,00	0,00	0,00
Sisačko-moslavačka	63,16	63,16	63,16
Šplitsko-dalmatinska	29,63	24,07	25,45
Šibensko-kninska	45,00	55,00	55,00
Varaždinska	39,29	14,29	14,29
Virovitičko-podravska	81,25	75,00	81,25
Vukovarsko-srijemska	90,32	80,65	77,42
Zadarska	29,41	26,47	38,24
Zagrebačka	23,53	14,71	14,71

TABLICA 5
 Udio jedinica lokalne samouprave klasificiranih u skupine koje zaostaju u razvoju po županijama

Na rezultatima klusterskih analiza provedena je *stepwise* kvadratna diskriminacijska analiza. Rezultati analize upućuju na to kako je varijabla prosječni izvorni prihodi po stanovniku najbolji diskriminator između klastera ($F = 362, p = 0$). Potrebno je napomenuti da je, nakon isključivanja općine Dugopolje iz analize, kao najbolji diskriminator između skupina dobivenih na temelju indeksa razvijenosti također izdvojena varijabla prosječni izvorni prihodi po stanovniku.


MULTIVARIJATNA KLASIFIKACIJA JEDINICA REGIONALNE SAMOUPRAVE

Klasifikacija jedinica regionalne samouprave provedena je s različitim brojem varijabli, jer je uočen problem multikolinearnosti pokazatelja. Provedena je klusterska analiza utemeljena na četiri pokazatelja, gdje je izostavljen pokazatelj prosječni izvorni prihodi po stanovniku (uzeti su pokazatelji: prosječan dohodak po stanovniku, prosječna stopa nezaposlenosti, kretanje stanovništva i udio obrazovanoga stanovništva). Provedena je i klusterska analiza utemeljena na pet pokazatelja, gdje je pokazatelj prosječni izvorni prihodi po stanovniku zamijenjen pokazateljem udio izvornih prihoda u ukupnim rashodima. Također, provedena je klusterska analiza utemeljena na 5 pokazatelja, gdje je pokazatelj prosječni izvorni prihodi

po stanovniku zamijenjen pokazateljem udio pomoći u ukupnim prihodima (uzeti su i pokazatelji: prosječan dohodak po stanovniku, prosječna stopa nezaposlenosti, kretanje stanovništva, udio obrazovanoga stanovništva). Iako su i alternativni pokazatelji korelirani s ostalim pokazateljima, nije uočen problem multikolinearnosti, pa se mogla provesti klasterijska analiza. Štoviše, manja korelacija varijabli čak je i poželjna.

Provedena je hijerarhijska i nehijerarhijska klasterijska analiza. Rezultati hijerarhijskih metoda na temelju 4, odnosno 5, pokazatelja razlikuju se u klasifikaciji 3 ili manje jedinica, dok se rezultati nehijerarhijskih metoda dobivenih na temelju 4 i 5 pokazatelja potpuno podudaraju. Rezultati nehijerarhijskih metoda jednaki su onima dobivenim hijerarhijskom Wardovom metodom utemeljenoj na 4 pokazatelja. Iz dendograma dobivenoga klasterijskom analizom Wardovom metodom danog u Grafikonu 2 vidi se da se izdvajaju četiri klastera.

GRAFIKON 2
Dendrogram
klasterijske analize
Wardovom metodom



Dakle, klasifikacije utemeljene na 5 pokazatelja potvrđuju klasifikaciju dobivenu na temelju 4 pokazatelja. Budući da su klasifikacije dobivene *K-means* metodom na temelju 4 i 5 pokazatelja jednake, nadalje su opisani rezultati dobiveni *K-means* metodom.

U Tablici 6 dane su prosječne vrijednosti socioekonomskih pokazatelja te pripadni koeficijenti varijacije, koji su dani u zagradaama.

Prvi klaster određen je područjima koja najviše zaostaju u razvoju. Prosječne vrijednosti pokazatelja prosječan dohodak po stanovniku, prosječni izvorni prihodi po stanovniku i udio obrazovanoga stanovništva najniže su među klasterima,

● TABLICA 6
 Prosječne vrijednosti socioekonomskih pokazatelja i pripadni koeficijenti varijacije klastera JRS dobivenih na temelju 4 pokazatelja

Klaster	Prosječan dohodak po stanovniku	Prosječni izvorni prihodi po stanovniku	Prosječna stopa nezapo- slenosti	Kretanje stanovništva	Udio obra- zovanoga stanovništva	Udio pomoći u ukupnim prihodima	Udio iz- vornih pri- hoda u ukupnim rashodima
1	18890,43 (8,46%)	1726,57 (27,10%)	19,90% (16,75%)	93,31 (4,99%)	55% (6,93%)	0,17 (24,50%)	0,59 (14,21%)
2	23125 (3,72%)	2606 (15,48%)	17,88% (12,22%)	74,52 (6,58%)	64% (5,71%)	0,17 (39,10%)	0,58 (8,96%)
3	23732,33 (10,21%)	2712,33 (27,27%)	11,35% (28,79%)	100,65 (5,06%)	65% (11,93%)	0,12 (32,87%)	0,66 (10,50%)
4	33493,67 (13,09%)	6000,33 (11,81%)	8,20% (21,19%)	99,23 (2,67%)	76% (4,77%)	0,04 (79,90%)	0,78 (3,99%)

dok je prosječna stopa nezaposlenosti najviša. Prosječan dohodak kreće se između 16 963 i 21 636 kuna po stanovniku, prosječni izvorni prihodi po stanovniku kreću se između 1290 i 2653 kune po stanovniku, a prosječna stopa nezaposlenosti kreće se između 14% i 24%. Vrijednosti pokazatelja kretanje stanovništva kreće se između 87,5 i 102,6, a vrijednosti pokazatelja udio obrazovanoga stanovništva kreće se između 49,4% i 61,4%. Većina se županija nalazi na prostoru Središnje i Istočne Hrvatske.

Drugi klaster sastoji se od županija s najvećim problemom depopulacije. Prosječna vrijednost pokazatelja kretanje stanovništva najniža je među klasterima, dok su prosječne vrijednosti ostalih pokazatelja veće u odnosu na prvi klaster, što upućuje na veći stupanj razvijenosti ovoga klastera. Prosječan dohodak po stanovniku kreće se između 22 147 i 24 270 kuna po stanovniku, prosječni izvorni prihodi po stanovniku kreću se između 2123 i 3301 kuna po glavi stanovnika, a prosječna stopa nezaposlenosti kreće se između 14,8% i 20,8%. Drugi klaster sadrži jedinice s najnižim vrijednostima pokazatelja kretanje stanovništva, vrijednost toga pokazatelja kreće se između 65,1 i 79,1. Vrijednost drugoga demografskog pokazatelja, udio obrazovanoga stanovništva, kreće se između 59,7% i 68,4%. Indeks razvijenosti županija u ovom klasteru kreće se između 48,5% i 75,6%.

Treći je klaster prema prosječnim vrijednostima pokazatelja prosječan dohodak po stanovniku, prosječni izvorni prihodi po stanovniku i udio obrazovanoga stanovništva vrlo sličan drugom klasteru, ali uz veće koeficijente varijacije. Prosječan dohodak po stanovniku kreće se između 19 630 i 26 959 kuna po stanovniku, prosječni izvorni prihodi po stanovniku kreću se između 1758 i 3448 kuna po stanovniku, udio obrazovanoga stanovništva kreće se između 55,7% i 74,9%. Pokazatelji koji upućuju na veći stupanj razvijenosti ovoga klastera u odnosu na drugi klaster jesu prosječna stopa nezaposlenosti, koja se kreće između 8% i 17%, i kretanje stanovni-

štva, koje se kreće između 96,4 i 110,6. Unatoč sličnosti drugoga i trećega klastera u većini socioekonomskih pokazatelja, velika je razlika u indeksu razvijenosti klastera. Vrijednost indeksa razvijenosti kreće se između 75% i 123%.

Četvrti klaster izdvaja najrazvijenije županije Republike Hrvatske. Prosječne vrijednosti svih pokazatelja pokazuju najviši stupanj razvijenosti ovoga klastera (prosječne vrijednosti pokazatelja prosječan dohodak po stanovniku, prosječni izvorni prihodi po stanovniku, kretanje stanovnika i udio obrazovanoga stanovništva više su od prosjeka svih jedinica, dok je prosječna stopa nezaposlenosti niža od prosjeka svih županija). Ovaj klaster jednak je najrazvijenijoj skupini dobivenoj na temelju indeksa razvijenosti, pa i vrijednosti samog indeksa pokazuju kako je riječ o daleko najrazvijenijim jedinicama regionalne samouprave. Indeks razvijenosti županija u ovom klasteru kreće se između 142,3% i 187,5%.

Najnerazvijenija područja Republike Hrvatske obuhvaćaju 26% stanovništva, a podjednako obuhvaćaju i najrazvijenija područja (29% stanovništva). Velika je razlika u površini između najrazvijenijih i najnerazvijenijih područja. Najnerazvijenija područja zauzimaju 30% površine, a najrazvijenija tek nešto više od 12% površine Republike Hrvatske. Ovakvom kategorizacijom županija najnerazvijenija skupina manja je i brojem stanovnika i površinom od najnerazvijenije skupine određene indeksom razvijenosti (indeksom razvijenosti najnerazvijenije područje čini čak 59% površine Republike Hrvatske i na njemu živi 37% stanovništva).

ZAKLJUČAK

Donošenjem Zakona o regionalnom razvoju Republika Hrvatska postavila je temelj za upravljanje modernom regionalnom politikom. Određivanje jedinica koje primaju državnu pomoć regulirano je kroz više zakona, a donošenjem ovoga zakona određena je kategorizacija područja koja zaostaju u razvoju na temelju indeksa razvijenosti. Novina je identifikiranje jedinica regionalne samouprave sa znatnim razvojnim poteškoćama, a ne samo jedinica lokalne samouprave. Indeks razvijenosti temelji se na pet pokazatelja: prosječan dohodak po stanovniku, prosječni izvorni prihodi po stanovniku, prosječna stopa nezaposlenosti, kretanje stanovništva i udio obrazovanoga stanovništva u stanovništvu od 16 do 65 godina, a dobiva se kao ponderirani prosjek odstupanja standardiziranih vrijednosti ovih pokazatelja od prosjeka Republike Hrvatske.

Cilj je ovoga rada prikazati alternativni pristup ocjenjivanju i kategorizaciji teritorijalnih jedinica prema socioekonomskoj razvijenosti utemeljen na multivarijantnoj analizi socioekonomskih obilježja jedinica lokalne i područne samo-

uprave. Multivarijatnim metodama klasterske i diskriminacijske analize na temelju istih pokazatelja provedena je klasifikacija jedinica lokalne samouprave prema razvijenosti. Na temelju istih pokazatelja te pokazatelja udio izvornih prihoda u ukupnim rashodima i udio pomoći u ukupnim prihodima jedinice regionalne samouprave svrstane su prema socioekonomskoj razvijenosti. Uočeni su i eliminirani problemi multikolinearnosti i problem postojanja izdvojenica. Kroz više klasterskih analiza jedinica lokalne i regionalne samouprave pokazano je kako se mogu iskoristiti multivarijatne metode u svrhu klasifikacije jedinica prema razvijenosti.

Razne metode klasterske analize jedinica lokalne samouprave daju slične rezultate. Najveći broj jedinica lokalne samouprave koji zaostaje u razvoju nalazi se na prostoru Središnje i Istočne Hrvatske, dok je uz Grad Zagreb najveći broj leaderskih jedinica s područja Primorsko-goranske i Istarske županije. Najveći hrvatski gradovi klasificirani su u klastere višega stupnja socioekonomske razvijenosti. Klasteri najnerazvijenijih jedinica obuhvaćaju manje od petine stanovništva Republike Hrvatske, ali i velik broj jedinica lokalne samouprave, oko jedne trećine. Zanimljivo je kako gotovo sve metode klasterske analize u poseban klaster izdvajaju jedinice lokalne samouprave koji imaju velik problem depopulacije, uz srednji stupanj ekonomske razvijenosti, što omogućuje da se jedinice lokalne samouprave toga klastera obuhvate posebnim mjerama poticanja demografskoga razvitka.

Metode klasterske analize jedinica regionalne samouprave potvrđuju postojanje velikih razlika u razvijenosti županija. Većina provedenih metoda daje jednake rezultate. U skladu s rezultatima klasterske analize jedinica lokalne samouprave, jedinice regionalne samouprave koje su klasificirane u klaster najnerazvijenijih jedinica većinom se nalaze na prostoru Središnje i Istočne Hrvatske, dok su tri najrazvijenije jedinice regionalne samouprave: Grad Zagreb, Istarska i Primorsko-goranska županija. Izdvojen je klaster županija s najvećim problemom depopulacije, koji ujedno bilježi i srednji stupanj ekonomske razvijenosti.

Neke od prednosti ove metodologije jesu otklanjanje problema multikolinearnosti i otklanjanje problema postojanja izdvojenica. Multivarijatnim metodama, za razliku od univarijatnih, ne gube se informacije i vodi se računa o povezanosti varijabli. Klasifikacija na temelju indeksa razvijenosti osjetljiva je na veličine pondera, koja ovisi isključivo o odluci istraživača, dok je utjecaj istraživača u multivarijatnoj klasifikaciji vezan uz odabir metode klasifikacije i mjere udaljenosti.

Zaključci ovoga rada otvaraju pitanje povezivanja ekonomskih i demografskih pokazatelja u jedan pokazatelj i iskazuju potrebu za ispitivanjem problema multikolinearno-

sti pokazatelja i problema postojanja izdvojenica. Također, rezultati prikazani u radu mogu poslužiti u budućim primjenama multivarijantnih tehnika u klasifikaciji lokalnih jedinica i istraživanju čimbenika regionalnoga razvoja.

Klasifikacijom u skupinu koja zaostaje u razvoju jedinica lokalne, odnosno regionalne, samouprave ostvaruje prava na razne mjere poticaja. Pogrešnom klasifikacijom bila bi uskraćena pomoć jedinicama kojima je pomoć potrebna, čime bi bio usporen njihov društveno-gospodarski razvoj, te bi se samo povećalo zaostajanje u razvoju za ostatkom zemlje. Stoga je problem klasifikacije jedinica prema socioekonomskoj razvijenosti od velike važnosti i potrebno je razmotriti više pristupa ocjenjivanju razvijenosti jedinica lokalne i regionalne samouprave. Jednako kako različite metode klsterske analize dovode do različitih rezultata, tako i različite veličine pondera u izračunu indeksa razvijenosti dovode do različite klasifikacije jedinica. Koja je najbolja, tj. najpravednija, klasifikacija teško je odgovoriti, pa je korisno usporedbom i kombiniranjem više metoda naći optimalan rezultat.

BILJEŠKE

¹ Velik broj autora kritizira prevelik broj lokalnih jedinica; na primjer: Ott i Bajo, 2001; Bratić, 2008; Kregar, 2011; Đulabić, 2011.

² U Zakonu o regionalnom razvoju definirano je kako status potpognutoga područja stječe jedinica lokalne i regionalne samouprave čija je vrijednost indeksa razvijenosti manja od 75% prosjeka Republike Hrvatske.

³ Ministarstvo regionalnog razvoja, šumarstva i vodnoga gospodarstva (2010). *Strategija regionalnog razvoja Republike Hrvatske 2011.-2013.*, Zagreb.

⁴ *Glavne novine koje donosi Nacrt prijedloga Zakona o regionalnom razvoju Republike Hrvatske*, Ministarstvo regionalnog razvoja i fondova Europske unije (2013).

⁵ Izračun autorice prema podacima iz tri izvješća Državnog zavoda za statistiku (Bruto domaći proizvod za Republiku Hrvatsku, prostorne jedinice za statistiku 2. razine i županije u 2008., 2007. i 2006. godini).

⁶ Na temelju *QQ-plota* i rezultata Shapiro-Wilksova testa odbacuje se pretpostavka o normalnoj distribuiranosti varijabli. Vrijednost Shapiro-Wilksove testne statistike manja je od 0,99 za sve varijable, a pripadna *p*-vrijednost manja je od 0,008.

⁷ U smislu da uzrokuju problem multikolinearnosti varijabli. Postojanje multikolinearnosti dovodi do problema nejednakoga položaja varijabli i otežava interpretaciju, jer je teško utvrditi utjecaj pojedine varijable. Visoko korelirane varijable imaju veći doprinos u mjerenju udaljenosti objekata jer zapravo opisuju sličan fenomen.

⁸ Odluka o razvrstavanju jedinica lokalne i područne (regionalne) samouprave prema stupnju razvijenosti (NN, 89/10).

⁹ Klsterska analiza s obuhvaćenim svim jedinicama lokalne samouprave (njih 556).

¹⁰ Općina Dugopolje isključena iz računa.

¹¹ Godine 2007. Republika Hrvatska podijeljena je na tri NUTS regije druge razine: Sjeverozapadna Hrvatska, Središnja i Istočna (Panonska) Hrvatska i Jadranska Hrvatska (NN, 35/07). Do promjene u broju regija NUTS II regija dolazi 2013. godine, kada su određene dvije regije: Kontinentalna Hrvatska i Jadranska Hrvatska (NN, 96/12). Kontinentalna Hrvatska stvorena je udruživanjem dviju regija NUTS II razine (u slučaju podjele na tri regije) Sjeverozapadne Hrvatske i Središnje i Istočne Hrvatske. U trenutku pisanja rada na snazi je bila stara klasifikacija, koja se rabi i u radu.

¹² Indeks razvijenosti jedinica kreće se između 57% i 97%.

¹³ Prema indeksu razvijenosti i multivarijatnim metodama, Međimurska županija svrstana je u skupinu srednjega stupnja razvijenosti.

LITERATURA

Bahovec, V. i Erjavec, N. (2009). *Uvod u ekonometrijsku analizu*. Zagreb: Element.

Ben Gal, I. (2005). Outlier detection. U O. Maimon i L. Rockach (Ur.), *Data mining knowledge discovery handbook: A complete guide for practitioners and researchers*. Kluwer Academic Publishers. Dostupno na <http://www.eng.tau.ac.il/~bengal/outlier.pdf>

Bratić, V. (2008). *Odlučivanje o lokalnim proračunima: između sna i jave*. Zagreb: Institut za javne financije.

Bruto domaći proizvod za Republiku Hrvatsku, prostorne jedinice za statistiku 2. razine i županije u 2008. (2011) [online] Zagreb: Državni zavod za statistiku Republike Hrvatske. Dostupno na http://www.dzs.hr/Hrv_Eng/publication/2011/12-01-02_01_2011.htm

Bruto domaći proizvod za Republiku Hrvatsku, prostorne jedinice za statistiku 2. razine i županije u 2007. (2008) [online] Zagreb: Državni zavod za statistiku Republike Hrvatske. Dostupno na http://www.dzs.hr/Hrv_Eng/publication/2010/12-01-02_01_2010.htm

Bruto domaći proizvod za Republiku Hrvatsku, prostorne jedinice za statistiku 2. razine i županije od 2000. do 2006. (2009) [online] Zagreb: Državni zavod za statistiku Republike Hrvatske. Dostupno na http://www.dzs.hr/Hrv_Eng/publication/2010/12-01-02_01_2010.htm

Czirák, D., Sambt, J., Rován, J. i Puljiz, J. (2005). Regional development assessment: A structural equation approach. *European Journal of Operational Research*, 174(1), 427–442. <http://dx.doi.org/10.1016/j.ejor.2005.03.012>

Đulabić, V. (2011). Razvoj i modernizacija regionalne samouprave u Hrvatskoj. U S. Ravlić (Ur.), *Decentralizacija* (str. 1–33). Zagreb: Centar za demokraciju i pravo Miko Tripalo.

Hair, J. F., Anderson, R. E., Tatham, R. L. i Black, W. C. (1995). *Multivariate data analysis: With readings*. Fourth edition. New Jersey: Prentice Hall.

Jurun, E. i Pivac, S. (2010). Cluster and multicriterial comparative regional analysis – case study of Croatian counties. *Croatian Operational Research Review*, 1, 113–122. Dostupno na http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=137548

DRUŠ. ISTRAŽ. ZAGREB
GOD. 23 (2014), BR. 2,
STR. 211-231

PERIŠIĆ, A.:
MULTIVARIJATNA...

Kesner Škreb, M. (2009) Regionalna politika Europske unije. *Financijska teorija i praksa*, 33(1), 103–105. Dostupno na http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=56881

Kregar, J. (2011). Decentralizacija. U S. Ravlić (Ur.), *Decentralizacija* (str. 1–33). Zagreb: Centar za demokraciju i pravo Miko Tripalo.

Kurnoga Živadinović, N. (2007). Multivarijatna klasifikacija županija Hrvatske, *Zbornik ekonomskog fakulteta u Zagrebu*, 5(1), 1–15. Dostupno na http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=29032

Lovrinčević, Ž., Marić, Z. i Rajh, E. (2005). Kako optimalno regionalizirati Hrvatsku? *Ekonomski pregled*, 56(12), 1109–1160. Dostupno na http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=16005

Ministarstvo financija, Arhiva proračuna jedinica lokalne i regionalne samouprave, Zagreb. Dostupno na <http://www.mfin.hr/hr/lokalni-proracun-2002>

Ministarstvo regionalnog razvoja i fondova Europske unije (2010a). *Vrijednosti indeksa razvijenosti i pokazatelja za izračun indeksa razvijenosti na lokalnoj razini*, Zagreb. Dostupno na <http://www.mrrfeu.hr/default.aspx?id=405>

Ministarstvo regionalnog razvoja i fondova Europske unije (2010b). *Vrijednosti indeksa razvijenosti i pokazatelja za izračun indeksa razvijenosti na županijskoj razini*, Zagreb. Dostupno na <http://www.mrrfeu.hr/default.aspx?id=405>

Ministarstvo regionalnog razvoja i fondova Europske unije (2013). *Glavne novine koje donosi Nacrt prijedloga Zakona o regionalnom razvoju Republike Hrvatske*, Zagreb. Dostupno na <http://www.mrrfeu.hr/UserDocsImages/Savjetovanje%20sa%20zainteresiranom%20javnošću/Glavne%20novine%20koje%20donosi%20Nacrt%20prijedloga.pdf>

Ministarstvo regionalnog razvoja, šumarstva i vodnoga gospodarstva (2010). *Strategija regionalnog razvoja Republike Hrvatske 2011.-2013.*, Zagreb.

Mooi, E. i Sarstedt, M. (2011). *A concise guide to marketing research*. Berlin Heidelberg: Springer. <http://dx.doi.org/10.1007/978-3-642-12541-6>

Odluka o razvrstavanju jedinica lokalne i područne (regionalne) samouprave prema stupnju razvijenosti. *Narodne novine*, 89/2010.

Ott, K. i Bajo, A. (2001). Lokalne financije i lokalni proračuni u Republici Hrvatskoj. *Financijska teorija i praksa*, 25(3), 311–434. Dostupno na http://hrcak.srce.hr/index.php?id_clanak_jezik=9161&show=clanak

Popis stanovništva, kućanstava i stanova 31. ožujka 2001. Zagreb: Državni zavod za statistiku. Dostupno na: <http://www.dzs.hr/>

Puljiz, J., Maleković, S., Polić, M. i Jurlin, K. (2005). *Novi pristup ocjenjivanju i kategorizaciji teritorijalnih jedinica prema razvijenosti*. Ministarstvo mora, turizma, prometa i razvitka. Dostupno na <http://www.mmtp.hr/UserDocsImages/CARDS.../akcijski.../prilog4.doc>

Rašić-Bakarić, I. (2006). Primjena faktorske i klaster analize u otkrivanju regionalnih nejednakosti. *Privredna kretanja i ekonomska politika*, 105, 53–76. Dostupno na http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=28749

Rašić-Bakarić (2012). A proposal for a new administrative-territorial division of the Republic of Croatia. *Economic Research – Ekonomska istraživanja*, 25(2), 307–412. Dostupno na http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=128953

DRUŠ. ISTRAŽ. ZAGREB
GOD. 23 (2014), BR. 2,
STR. 211-231

PERIŠIĆ, A.:
MULTIVARIJATNA...

Rimac, I., Rihtar, S. i Oliveira Roca, M. (1992). Multivarijatna klasifikacija općina Hrvatske kao moguća metoda regionalizacije Republike. *Društvena istraživanja*, 1(1), 87–99. Dostupno na http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=51859

Sambandam, R. (2003). Cluster analysis gets complicated. *Marketing Research*, 15(1), 16–21. Dostupno na <http://www.trchome.com/component/content/article/66-published-articles/146-cluster-analysis.html>

Statsoft Electronic Statistics Textbook (2012). StatSoft Inc, Dostupno na <http://www.statsoft.com/textbook/discriminant-function-analysis/#assumptions>

Timm, H. N. (2002). *Applied multivariate statistics*. New York: Springer.

Uredba o indeksu razvijenosti. *Narodne novine*, 63/2010.

Zakon o regionalnom razvoju Republike Hrvatske. *Narodne novine*, 153/2009.

Multivariate Classification of Local and Regional Government Units According to Socio-Economic Development

Ana PERIŠIĆ
Polytechnic of Šibenik, Šibenik

One of the key problems of economic policy of the Republic of Croatia is the problem of uneven regional development. The Law on regional development of the Republic of Croatia regulates the evaluation and classification of local and regional government units. The classification is based on the level of development as measured by the development index. This univariate classification relies on the value of a single variable that is a linear combination of the standardized values of indicators, and this causes a loss of information. The goal of this paper is to demonstrate an alternative approach to the evaluation and socio-economic classification of territorial units based on multivariate analysis. The local and regional government units are evaluated using the multivariate methods based on five socio-economic indicators. Special emphasis is placed on undeveloped regions. In the analysis of the results, problems of multicollinearity and outlier existence, which exist in the classification based on development index, are encountered and eliminated. The results confirm high disparities in regional development. Almost all cluster methods result in the formation of a separate cluster, which could not have been foreseen from the classification based on the development index. Such a cluster contains local and regional units that are not highly undeveloped but have a large depopulation problem. Consequently, units that need to be subjected to a specific demographic development program can be indicated.

Keywords: multivariate analysis, regional disparities, classification, socio-economic development, development index