

2. Primjena faktorske i klaster analize

regionalnih nejednakosti

Ivana Rašić Bakarić*

Sažetak

Cilj rada je prikazati metodologiju klasifikacije prostorno-gospodarskih cjelina na temelju društveno-gospodarskih obilježja dijelova promatranog prostora kako bi se dala potpora i osnova politici regionalnog razvoja. Rad pokazuje da se korištenjem metoda faktorske i klaster analize mogu analitički izdvojiti jedinice lokalne samouprave koje su prikladnijim predmetom instrumenata i mjera regionalne politike. Promatrani prostor čine jedinice lokalne samouprave (JLS) (gradovi i općine) triju odabranih županija: Istarske, Ličko-senjske i Primorsko-goranske županije. Klasifikacija je izvršena primjenom metoda multivarijatne statistike, faktorske i klaster analize, a zasniva se na jedanaest (11) pokazatelja društveno-gospodarskog razvoja. Na temelju odabranih društvenih, gospodarskih i demografskih pokazatelja, korištenjem faktorske analize (analize glavnih komponenata), dobivaju se faktori koji predstavljaju glavne dimenzije društveno-gospodarskog razvoja promatranog prostora. Klaster analizom se na temelju zastupljenosti svake od dobivenih dimenzija u pojedinoj jedinici lokalne samouprave, iste svrstavaju u grupe (klasterne). Tako dobiveni klasteri su homogeni, sastavljeni su od gradova i općina sličnih društveno-gospodarskih obilježja. Primjenom metoda faktorske i klaster analize analitički su izdvojene jedinice lokalne samouprave sličnih obilježja koje su kao takve prikladniji predmet instrumenata i mjera regionalne politike.

Ključne riječi: faktorska analiza, klaster analiza, regije, regionalna politika

JEL klasifikacija: C49, R12, R58

* Ivana Rašić Bakarić, asistent, Ekonomski institut, Zagreb.

1. Uvod

Promatrani prostor sačinjavaju tri županije Republike Hrvatske: Istarska, Ličko-senjska i Primorsko-goranska županija, a predmet analize su jedinice lokalne samouprave spomenutih županija. Tako oblikovanu prostornu jedinicu obilježavaju značajne razlike od primorskog dijela Istre i Kvarnera zajedno s otocima, do kontinentalnog prostora Istre, brdsko-planinskog dijela Gorskog kotara i Like. Tri su županije u prvotnom prijedlogu za uspostavu Nomenklature prostornih jedinica za statistiku (NUTS) sačinjavale jednu od regija druge NUTS razine¹. Upravo je druga NUTS razina glavni okvir za provedbu regionalne politike i mjerodavna za analizu regionalnih problema. Uzevši u obzir različitost prostora, provođenje jedinstvenih mjera regionalne politike kako na prostoru svake od te tri županije tako i na prostoru te tri županije kao jedne regionalne cjeline, neće dovesti do jednakih i željenih učinaka. Preduvjet koji bi trebao biti zadovoljen prije formuliranja ciljeva i mjera regionalne politike, je provedena analiza društvenih i gospodarskih obilježja nekog prostora. Radom se želi ukazati na primjenu faktorske i klaster analize u prepoznavanju obilježja određenih prostornih jedinica te u grupiranju tih jedinica u homogene grupe.

U promatranoj 2001. godini u odabranim se županijama nalazi osamdeset i šest (86) jedinica lokalne samouprave (JLS-a). Kao i na prostoru Republike Hrvatske pitanja regionalnog razvoja ovih jedinica lokalne samouprave regulirana su Zakonom o lokalnoj i područnoj samoupravi (Narodne Novine 33/01). Postoji i čitav niz zakona koji se odnose na određena područja sličnih karakteristika (Zakon o područjima posebne državne skrbi, Zakon o otocima, Zakon o Gradu Vukovaru i Zakon o brdsko-planinskim područjima). Međutim, odabir tih područja bio je prilično arbitraran i kao takav nije rezultat ekonomskih analiza temeljnih

¹ Prema prvotnom prijedlogu uspostave NUTS regija, usvojenom od strane Hrvatskog Sabora, Hrvatska se dijeli na pet regija druge NUTS razine. Međutim, EUROSTAT - ured za statistiku Europske unije prijedlog je odbio i prihvatio je novi kojim se Hrvatska dijeli na četiri regije druge NUTS razine: Istočna Hrvatska (Virovitičko-podravska županija, Osječko-baranjska županija, Vukovarsko-srijemska županija, Brodsko-posavska županija i Požeško-slavonska županija), Jadranska Hrvatska, Središnja Hrvatska (Krapinsko-zagorska županija, Varaždinska županija, Međimurska županija, Koprivničko-križevačka županija, Bjelovarsko-bilogorska županija, Sisačko-moslavačka županija, Karlovačka županija) i Zagrebačka regija (Grad Zagreb i Zagrebačka županija).

karakteristika nekog prostora. Bez toga nije moguće definirati i provoditi mjere regionalne politike kao niti pratiti njihove učinke.

Osnovna hipoteza rada je pokazati da se korištenjem metoda faktorske i klaster analize mogu analitički izdvojiti jedinice lokalne samouprave koje su prikladnijim predmetom instrumenata i mjera regionalne politike.

Nakon što se korištenjem faktorske analize odrede osnovne dimenzije društveno-gospodarskog razvoja promatranih jedinica lokalne samouprave, one jedinice koje su po dobivenim dimenzijama slične svrstavaju se u klustere.

2. Jedinice lokalne samouprave odabranih županija

U 2001. godini u promatrane tri županije nalazi se dvadeset i osam (28) gradova i pedeset i osam (58) općina. Ukupno osamdeset i šest (86) jedinica lokalne samouprave.

U Istarskoj županiji nalazi se deset (10) gradova (Buje, Buzet, Labin, Novigrad, Pazin, Poreč, Pula, Rovinj, Umag i Vodnjan) i dvadeset i devet (29) općina (Bale, Barban, Brtonigla, Cerovlje, Fažana, Gračišće, Grožnjan, Kanfanar, Karojba, Kaštelir - Labnici, Kršan, Lanišće, Ližnjan, Lupoglav, Marčana, Medulin, Motovun, Oprtalj, Pićan, Raša, Sveta Nedelja, Sveti Lovreč, Sveti Petar u Šumi, Svetvinčenat, Tinjan, Višnjan, Vižinada, Vrsar, Žminj). Sjedište Županije je grad Pazin.

U Ličko-senjskoj županiji se nalazi četiri (4) grada (Gospić, Novalja, Otočac, Senj) i osam (8) općina (Brinje, Donji Lapac, Karlobag, Lovinac, Perušić, Plitvička Jezera, Udbina i Vrhovine). Sjedište Županije je grad Gospić.

Primorsko-goranska županija broji četrnaest (14) gradova (Bakar, Cres, Crikvenica, Čabar, Delnice, Kastav, Kraljevica, Krk, Mali Lošinj, Novi Vinodolski, Opatija, Rab, Rijeka, Vrbovsko) i dvadeset i jednu (21) općinu (Baška, Brod Moravice, Čavle, Dobrinj, Fužine, Jelenje, Klana, Kostrena, Lokve, Lovran, Malinska-

Dubašnica, Matulji, Mošćenička Draga, Mrkopalj, Omišalj, Punat, Ravna Gora, Skrad, Vinodolska općina, Viškovo, Vrbnik). Sjedište Županije je grad Rijeka.

Kao i na prostoru Republike Hrvatske pitanja regionalnog razvoja ovih jedinica lokalne samouprave regulirana su Zakonom o lokalnoj i područnoj samoupravi (Narodne Novine 33/01). One jedinice lokalne samouprave odabranih županija koje se nalaze bilo u područjima posebne državne skrbi bilo na otocima ili u brdsko-planinskim područjima, dodatno su regulirane posebnim zakonima (Zakon o područjima posebne državne skrbi (Narodne novine 44/96, 57/96, 124/97, 73/00, 87/00, Zakon o otocima, Narodne novine, 34/99, Zakon o brdsko-planinskim područjima, Narodne Novine brojevi 12/02,32/02,117/03)². Zakonom o područjima posebne državne skrbi dodatno su regulirane sljedeće jedinice lokalne samouprave. Općine Donji Lapac i Plitvička Jezera pripadaju Prvoj skupini područja državne skrbi. Grad Gospić, općine Lovinac i Udbina pripadaju drugoj skupini područja posebne državne skrbi. Trećoj skupini područja posebne državne skrbi pripadaju općine Brinje, Brod Moravice, Grožnjan, Lanišće, Oprtalj, Perušić.

Predmetom mjera propisanih Zakonom o brdsko-planinskim područjima su: Buzet, Cerovlje, Gračišće, Lupoglav, Motovun, Senj, Karlobag, Čabar, Delnice, Vrbovsko, Čavle, Fužine, Jelenje, Lokve, Matulji, Mrkopalj, Ravna Gora, Skrad i Vinodolska općina.

Zakonom o otocima regulirane su jedinice lokalne samouprave koje se rasprostiru na području istarskog otočja (porečko, vrsarsko, rovinjsko, brijunsko, pulsko i medulinsko otočje), zatim jedinice lokalne samouprave na otoku Krku, Malom Lošinju, Rabu, te Novalja na otoku Pagu.

² Ti zakoni, uz Zakon o obnovi i razvoju Grada Vukovara te Zakon o Fondu za regionalni razvoj, predstavljaju pet zakona koji eksplicitno reguliraju pitanja vezana uz regionalni razvoj. Pored tih, postoji niz zakona koji na indirektnan način reguliraju pojedina pitanja vezana uz razvoj jedinica lokalne samouprave.

3. Podaci korišteni u analizi – pokazatelji društveno-gospodarskog razvoja

Cilj analize je grupirati gradove i općine u homogene grupe (klustere) s obzirom na zastupljenost pojedinih obilježja društveno-gospodarskog razvoja. U tu svrhu kao ulazne varijable za faktorsku analizu odabrano je jedanaest varijabli, pokazatelja društveno-gospodarskog razvoja mjerenih na razini promatranih gradova i općina. To su: vlastiti prihodi JLS-a po glavi stanovnika, udio zaposlenih u djelatnosti Poljoprivrede i djelatnosti Ribarstva u ukupnom broju zaposlenih, udio zaposlenih u djelatnosti Prerađivačka industrija u ukupnom broju zaposlenih, udio zaposlenih u djelatnosti Hoteli i restorani te djelatnosti Poslovanje nekretninama, iznajmljivanje i poslovne usluge u ukupnom broju zaposlenih, stopa nezaposlenosti, koeficijent starenja, vitalni indeks, udio stanovništva bez škole u ukupnom stanovništvu, broj noćenja turista, bruto domaći proizvod (BDP) po glavi stanovnika te udio zaposlenih u ukupnom stanovništvu. Svi se podaci odnose na 2001. godinu.

Oznaka	Opis
X1	Vlastiti prihodi jedinice lokalne samouprave po glavi stanovnika
X2	Udio zaposlenih u djelatnosti Poljoprivrede i djelatnosti Ribarstva u ukupnom broju zaposlenih
X3	Udio zaposlenih u djelatnosti Prerađivačka industrija u ukupnom broju zaposlenih
X4	Udio zaposlenih u djelatnosti Hoteli i restorani te djelatnosti Poslovanje nekretninama, iznajmljivanje i poslovne usluge u ukupnom broju zaposlenih.
X5	Stopa nezaposlenosti
X6	Koeficijent starenja
X7	Vitalni indeks
X8	Udio stanovništva bez škole u ukupnom stanovništvu
X9	Broj noćenja turista
X10	Bruto domaći proizvod po glavi stanovnika
X11	Udio zaposlenih u ukupnom stanovništvu

Izvor: *Vlastiti rad.*

Vlastiti prihodi jedinice lokalne samouprave po glavi stanovnika. Varijabla obuhvaća vlastite prihode od imovine i drugih neporeznih izvora, kao i prihode od vlastitih

poreza. U većini županija, gradova i općina su vrlo skromni i nedovoljni za financiranje poslova iz samoupravnog djelokruga. No kao takvi bolji su pokazatelj gospodarske snage JLS-a od ukupnih prihoda JLS-a jer ne uključuju zajedničke poreze i razne dotacije iz državnog proračuna. Izvor podataka su proračuni jedinica lokalne samouprave koje objavljuje Ministarstvo financija³. Tablica 2. sadrži srednje vrijednosti varijabli nad kojima je izvršena faktorska analiza (aritmetička sredina, i medijan) te standardnu devijaciju kao mjeru disperzije. Promotri li se tablica, uočava se velika varijacija u veličini vrijednosti ovog pokazatelja unutar promatranih gradova i općina. Tako, na primjer, najmanji vlastiti prihod po glavi stanovnika ima proračun općine Gračiče u visini od 42,8 kune, a najviši proračun općine Kostrena u visini od 7.092,00 kune. Prosječna visina vlastitih prihoda proračuna promatranih jedinica lokalne samouprave u 2001. godini iznosila je 1.189,20 kune, a čak je polovica promatranih jedinica ostvarila vlastite prihode u iznosu manjem od 869,53 kune.

Kao pokazatelji gospodarske strukture promatranih jedinica lokalne samouprave korišteni su: udio zaposlenih u djelatnosti Poljoprivrede i djelatnosti Ribarstva u ukupnom broju zaposlenih, zatim udio zaposlenih u djelatnosti Prerađivačke industrije, te udio zaposlenih u Hotelima i restoranima te Poslovanju nekretninama, iznajmljivanju i poslovnim uslugama u ukupnom broju zaposlenih⁴ te broj noćenja turista. Izvor podataka za prva tri pokazatelja je "Popis stanovništva, kućanstava i stanova 31. ožujka 2001."

Udio zaposlenih u djelatnosti Poljoprivrede i djelatnosti Ribarstva u ukupnom broju zaposlenih. Ova varijabla ukazuje na zastupljenost primarnog sektora u strukturi gospodarstva promatranog grada/općine. Dobivena je na način da se zbroji broj zaposlenih u te dvije djelatnosti te se podijeli s ukupnim brojem zaposlenih u

³ *Financiranje jedinica lokalne i područne (regionalne) samouprave uređeno je Zakonom o financiranju lokalne samouprave i uprave. Tim se zakonom uređuju izvori sredstava za financiranje poslova iz samoupravnog djelokruga županija, gradova i općina, te prenijeti poslovi državne uprave prema posebnim zakonima. Financijska sredstva za financiranje tih poslova osiguravaju se lokalnim proračunima kao vlastiti izvori (prihodi od vlastite imovine i drugi neporezni prihodi, te prihodi od županijskih odnosno općinskih ili gradskih poreza), kao udio u zajedničkim porezima i dotacije iz državnog i županijskog proračuna.*

⁴ *Broj zaposlenih po djelatnostima prikuplja se prema Nacionalnoj klasifikaciji djelatnosti (NKD) utemeljenoj na Europskoj klasifikaciji djelatnosti NACE, Rev. 1 koja je obavezna za sve države članice Europske unije. Klasifikacija djelatnosti NACE, Rev. 1 koristi se od 1995. godine prema Europskom sustavu nacionalnih računa 1995 (ESA 1995).*

promatranom gradu/općini. I za ovu je varijablu karakterističan veliki raspon u njenoj vrijednosti po promatranim jedinicama lokalne samouprave. Najmanje zaposlenih u ove dvije djelatnosti u 2001. godini bilo je u Bakru (0,7 posto), a najviše u Delnicama (54 posto). U istom je razdoblju u ovim djelatnostima, u svim promatranim jedinicama lokalne samouprave, u prosjeku bilo 8,7 posto zaposlenih (Tablica 2.).

Varijabla *udio zaposlenih u Prerađivačkoj industriji u ukupnom broju zaposlenih* promatranog grada/općine ukazuje na zastupljenost sekundarnog sektora u gospodarstvu promatrane jedinice lokalne samouprave. Varijabla je dobivena na način kao i prethodna, s tom razlikom da se sada u brojniku nalazi podatak o broju zaposlenih u djelatnosti Prerađivačke industrije. Najmanji udio zaposlenih u toj djelatnosti, 3,2 posto u 2001. godini, zabilježen je u općini Brod Moravice, a najveći, 47 posto u općini Mrkopalj. Prosječna je vrijednost ovog pokazatelja za promatrane jedinice lokalne samouprave u 2001. godini iznosila 20,7 posto. Polovica promatranih jedinica ima vrijednost ovog pokazatelja manju od 21,9 posto (Tablica 2.).

Udio zaposlenih u djelatnosti Hoteli i restorani te djelatnosti Poslovanje nekretninama, iznajmljivanje i poslovne usluge u ukupnom broju zaposlenih. Ova varijabla mjeri zastupljenost turizma kao predstavnika tercijarnog sektora u pojedinoj promatranoj jedinici. Vrijednost pokazatelja se izračunava na način da se zbroj zaposlenih u te dvije djelatnosti podijeli s ukupnim brojem zaposlenih u promatranoj jedinici lokalne samouprave. Raspon kretanja vrijednosti pokazatelja je od 3,4 posto zaposlenih u te dvije djelatnosti (općina Vrhovine) do 47 posto zaposlenih u te dvije djelatnosti (općina Vrsar). U promatranim gradovima i općinama u sve tri županije u prosjeku je 17,0 posto zaposlenih zaposleno u ove dvije djelatnosti (Tablica 2.).

Broj noćenja turista također je pokazatelj zastupljenosti turističkog sektora. Podatak o broju noćenja turista po promatranim gradovima i općinama uzet je iz publikacije Državnog zavoda za statistiku pod nazivom Statističko izvješće Turizam 1162/2002 za 2001. godinu.

Kao pokazatelji kvalitete života i rada korišteni su: stopa nezaposlenosti, udio stanovništva bez škole u ukupnom stanovništvu, zatim udio zaposlenih u ukupnom stanovništvu te visina bruto domaćeg proizvoda po glavi stanovnika.

Stopa nezaposlenosti. Za izračun stope nezaposlenosti korištena je standardna definicija stope nezaposlenosti koja stavlja u omjer broj nezaposlenih i ukupno aktivno stanovništvo. Aktivno stanovništvo čine zaposleni u radnom odnosu, osobe koje aktivno obavljaju neko zanimanje, ali nisu u radnom odnosu te nezaposleni. Podaci o aktivnom stanovništvu te o broju nezaposlenih u promatranim jedinicama lokalne samouprave dobiveni su Popisom stanovništva iz 2001. godine. Raspon vrijednosti ovog pokazatelja prilično je velik (vidi Tablica 2.). Najniža stopa nezaposlenosti izmjerena je u općini Sveti Petar u Šumi (6,7 posto), a najveća u visini od 70,0 posto u općini Donji Lapac. U polovici promatranih gradova/općina stopa nezaposlenosti u 2001. godini bila veća ili jednaka od 16,4 posto. Prosječna je stopa nezaposlenosti u svim promatranim jedinicama iznosila 17,5 posto.

Postotak stanovništva bez škole u ukupnom stanovništvu. Ovaj pokazatelj ukazuje na postotak neobrazovanog stanovništva. Vrijednost pokazatelja dobivena je stavljanjem u omjer podataka o broju stanovništva bez škole i ukupnog broja stanovnika. Najmanji udio stanovništva bez škole u 2001. godini, zabilježen je u općini Punat (0,3 posto), a najveći u općini Vrhovine (13 posto). Aritmetička sredina ovog pokazatelja iznosi 2,3 posto, a medijan 1,5 posto (vidi Tablica 2.). Vrijednosti pokazatelja izračunate su na temelju podataka iz "Popis stanovništva, kućanstava i stanova 31. ožujka 2001.", Državnog zavoda za statistiku.

Udio zaposlenih u ukupnom stanovništvu. Za izračun vrijednosti ovog pokazatelja korišteni su podaci o broju zaposlenih i ukupnom stanovništvu promatranog grada/općine. Kao što je prikazano u Tablici 2. vrijednost pokazatelja kreće se u rasponu od 11,2 posto zaposlenih u ukupnom stanovništvu u općini Donji Lapac do 45 posto zaposlenih u ukupnom stanovništvu u Buzetu. Čak polovica gradova i općina odabranih županija bilježi vrijednost ovog pokazatelja veću ili jednaku od 36,7 posto. U prosjeku je u promatranim jedinicama u 2001. godini bilo 35,6 posto zaposlenih u ukupnom stanovništvu. Pokazatelj je izračunat na osnovu podataka dobivenih Popisom stanovništva, kućanstava i stanova 2001. godine.

Bruto domaći proizvod po glavi stanovnika. Službena statistika podatke o bruto domaćem proizvodu prikazuje samo na nacionalnoj razini. Vrijednost BDP-a na razini gradova i općina dobivena je procjenom uz korištenje pretpostavke konstantne produktivnosti rada. Udio zaposlenih u svakoj od 17 djelatnosti (prema Nacionalnoj klasifikaciji djelatnosti) u određenom gradu/općini množi se s bruto dodanom vrijednošću (BDV-om) te djelatnosti na razini Hrvatske. Zatim se zbroje procijenjene bruto dodane vrijednosti svih djelatnosti te se na odgovarajući način izračuna odnosno procijeni bruto domaći proizvod grada/općine⁵. Taj se pokazatelj stavlja u omjer s brojem stanovnika grada/općine. Pogleda li se Tablica 2., promatrane su jedinice lokalne samouprave u 2001. godini u prosjeku proizvele 37.680,7 kuna po glavi stanovnika. Najniži procijenjeni BDP po glavi stanovnika ostvaren je u općini Vrhovine (8.968,5 kuna), a najviši u iznosu od 62.207,0 kuna u općini Medulin. Polovica promatranih gradova/općina u 2001. godini je ostvarila BDP po glavi stanovnika veći ili jednak od 39.052,8 kune. Procjena je izvršena korištenjem podataka iz popisa stanovništva provedenog 2001. godine i Statističkog ljetopisa 2002.

Koeficijent starosti i vitalni indeks. Od pokazatelja koji ukazuju na demografsku strukturu stanovništva, odabrani su koeficijent starosti i vitalni indeks. Koeficijent starosti predstavlja udio osoba starih 60 i više godina u ukupnom stanovništvu⁶. Kad udio osoba starih „60 i više godina“ dostigne 12 posto, smatra se da je stanovništvo te zemlje ili područja počelo starjeti (Wertheimer-Baletić, 1999). Vitalni indeks⁷ se također koristi za ocjenu razine starosti stanovništva i stupnja starenja. Predstavlja sintezu između pokazatelja prirodnog kretanja (mortaliteta (m) i fertiliteta (f)) i dobne strukture stanovništva (Wertheimer-Baletić, 1999). Među

⁵ *Bruto domaći proizvod u tržišnim cijenama iskazuje vrijednost svih proizvedenih dobara i usluga rezidentnih jedinica, tj. zbroj dodanih vrijednosti po djelatnostima uz uključivanje u obračun na razini nacionalnog gospodarstva stavki koje nisu raspoređene po djelatnostima: usluge financijskog posredovanja indirektno mjerene (UFPIM) i porezi na proizvode minus subvencije na proizvode (Statistički ljetopis, 2004).*

⁶ Izraz za izračun koeficijenta starosti je: $x_{(60i\ više)} = \frac{P_{60+}}{P} \times 100$, pri čemu je P_{60+} broj stanovnika starih 60 i više godina, a P ukupan broj stanovnika.

⁷ Vitalni se indeks izračunava prema sljedećoj formuli: $V = \frac{f \times \frac{P_{(20-39)}}{P}}{m \times x_s} \times 100$. Pri tome je $P_{(20-39)}$ broj stanovnika u dobi između 20 i 39 godina, P ukupan broj stanovnika, a x_s koeficijent starenja.

promatranim jedinicama lokalne samouprave u 2001. godini najmanja vrijednost koeficijenta starenja, 12,8 posto zabilježena je u općini Omišalj, dok je najveća od čak 51 posto vrijednost zabilježena u općini Lovinac (Tablica 2.). U istom je vremenskom trenutku najveća vrijednost vitalnog indeksa od 209 posto ostvarena u općini Viškovo, a najmanja 6,3 posto u općini Lanišće. Može se zaključiti da je sve jedinice zahvatio proces starenja, s napomenom da neke imaju dobar demografski potencijal. Izvor podatka je “Popis stanovništva, kućanstava i stanova 31. ožujka 2001.”

Tablica 2. Deskriptivna statistika ulaznih varijabli (pokazatelja društveno-gospodarskog razvoja JLS-a)						
Varijabla	Deskriptivna statistika					
	n	Aritmetička sredina	Medijan	Minimum	Maksimum	Standardna devijacija
X1	86	1.189,2	869,5	42,8	7092	1.223,5
X2	86	8,7	6,1	0,7	54	8,1
X3	86	20,7	21,9	3,2	47	11,5
X4	86	17,0	14,2	3,4	47	10,1
X5	86	17,5	16,4	6,7	70	8,0
X6	86	25,9	25,5	12,8	51	6,8
X7	86	66,7	62,7	6,3	209	35,0
X8	86	2,3	1,5	0,3	13	2,5
X9	86	314.526,0	8.151,5	0,0	4.896.520	709.260,8
X10	86	37.680,7	39.052,8	8.968,5	62.207	8.552,1
X11	86	35,6	36,7	11,2	45	5,6

Izvor: Podaci Državnog zavoda za statistiku, Ministarstva financija, vlastiti izračuni.

4. Identificiranje osnovnih dimenzija društveno-gospodarskog razvoja korištenjem faktorske analize

Faktorska se analiza koristi kako bi se utvrdio manji broj dimenzija društvenog i gospodarskog razvoja koje na prikladan način sažimaju informacije sadržane u originalnom skupu varijabli.

Budući da se unaprijed ne postavlja hipoteza o broju i nazivu faktora, koristi se eksplorativna faktorska analiza. Izvedeni faktori bit će međusobno nezavisne

linearne kombinacije originalnih, međusobno koreliranih varijabli. Nakon što je izvršen odabir ulaznih varijabli, kao i standardizacija njihovih vrijednosti, potrebno je ispitati opravdanost primjene same analize te donijeti odluku o odabiru metode faktorske analize. Stoga se prvo računa i ispituje korelacijska matrica originalnih varijabli. Ukoliko postoje visoke korelacije između manifestnih varijabli, faktorska je analiza opravdana. Najčešće korištene metode faktorske metode komponentne analize⁸ i metoda zajedničkih faktora. Odabir metode ovisi o cilju analize. Ovisno o lakoći tumačenja dobivenih rješenja, odlučuje se o eventualnom rotiranju faktora. Obzirom da će se rezultati ove analize koristiti kao ulazne varijable u klaster analizi, potrebno je i izračunati faktorske bodove⁹.

4.1. Ispitivanje opravdanosti korištenja faktorske analize

Ispitivanje prikladnosti korištenja faktorske analize podrazumijeva ocjenjivanje da li su ulazne, manifestne varijable¹⁰ signifikantno i dovoljno korelirane. Samo ako su manifestne varijable međusobno korelirane, mogu se određivati faktori kao hipotetičke komponentne međusobno nekorelirane varijable, a dovoljne za izražavanje manifestnih varijabli¹¹.

Tablica 3. prikazuje korelacijsku matricu manifestnih varijabli. Korelacijska matrica pokazuje da svaka varijabla ima barem jedan koeficijent korelacije s apsolutnom vrijednošću većom od 0.3, a to je minimalna vrijednost koju Kinnear i Gray (1994) predlažu kao kriterij za uključivanje varijable u analizu. Stoga je svih jedanaest varijabli uključeno u analizu. U Tablici 3. označeni su oni koeficijenti korelacije, koji su signifikantni uz razinu signifikantnosti od 5 posto.

⁸ Najčešće korištena i najpoznatija metoda komponentnih analiza je metoda glavnih komponentata.

⁹ Komponentna analiza se koristi kada je cilj sažeti većinu originalnih informacija (varijance) minimalnim brojem faktora u svrhu predviđanja te kada se rezultati faktorske analize koriste kao ulazne varijable za naredne analize. Analiza zajedničkih faktora se koristi kako bi se identificirali podržavajući faktori ili dimenzije koje nije lako opaziti.

¹⁰ Originalne varijable koje se promatraju u faktorskoj analizi nazivaju se manifestne varijable.

¹¹ Faktorska analiza i faktorski modeli su primjenjivi na one varijable koje su međusobno zavisne, tj. koje su u korelaciji.

Tablica 3. **Korelacijska matrica ulaznih varijabli**

	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11
X1	1,00	-0,26	-0,07	0,28	-0,02	-0,36	0,36	-0,23	0,29	0,13	0,25
X2	-0,26	1,00	-0,25	-0,22	0,19	0,61	-0,38	0,67	-0,21	-0,55	-0,50
X3	-0,07	-0,25	1,00	-0,63	-0,25	-0,13	-0,05	-0,29	-0,33	0,34	0,21
X4	0,28	-0,22	-0,63	1,00	-0,12	-0,31	0,27	-0,25	0,56	0,06	0,30
X5	-0,02	0,19	-0,25	-0,12	1,00	0,25	-0,23	0,46	-0,03	-0,55	-0,69
X6	-0,36	0,61	-0,13	-0,31	0,25	1,00	-0,58	0,68	-0,33	-0,69	-0,81
X7	0,36	-0,38	-0,05	0,27	-0,23	-0,58	1,00	-0,39	0,26	0,43	0,49
X8	-0,23	0,67	-0,29	-0,25	0,46	0,68	-0,39	1,00	-0,19	-0,73	-0,75
X9	0,29	-0,21	-0,33	0,56	-0,03	-0,33	0,26	-0,19	1,00	0,14	0,26
X10	0,13	-0,55	0,34	0,06	-0,55	-0,69	0,43	-0,73	0,14	1,00	0,86
X11	0,25	-0,50	0,21	0,30	-0,69	-0,81	0,49	-0,75	0,26	0,86	1,00

Izvor: Podaci Državnog zavoda za statistiku, Ministarstva financija, vlastiti izračuni.

4.2. Odabir metode faktorske analize, kriteriji za donošenje odluke o broju faktora, rezultati analize

Odabir metode faktorske analize ovisi o cilju analize. Kao što je već spomenuto dvije su osnovne metode faktorske analize, metoda glavnih komponenti i metoda zajedničkih faktora. Obzirom da će se rezultati faktorske analize koristiti kao ulazne varijable za klaster analizu (u koju svrhu se moraju izračunati i faktorski bodovi), preporuča se korištenje metode glavnih komponenata (Morrison, 1987). Metodom glavnih komponenata moguće je direktno određivanje faktorskih bodova za razliku od metode zajedničkih faktora gdje se ti bodovi procjenjuju. Prilikom odabira broja faktora primijenjen je kriterij svojstvene vrijednosti prema kojem količina varijacija objašnjena svakim faktorom mora biti veća od 1. Nerotirani faktori dobiveni analizom glavnih komponenata 11 varijabli na 86 općina i gradova tri promatrane županije prikazani su u Tablici 4.

Ulazne varijable	Faktori		
	1	2	3
X1	-0,39	-0,38	0,52
X2	0,72	-0,06	-0,34
X3	-0,20	0,85	0,27
X4	-0,38	-0,79	-0,28
X5	0,56	-0,30	0,61
X6	0,87	0,07	-0,18
X7	-0,63	-0,22	0,21
X8	0,85	-0,16	-0,00
X9	-0,37	-0,66	-0,06
X10	-0,85	0,31	-0,12
X11	-0,92	0,12	-0,24
Objašnjena varijanca	4,75	2,20	1,06
Proporcija objašnjene varijance	0,43	0,20	0,10

Izvor: Podaci Državnog zavoda za statistiku, Ministarstva financija, vlastiti izračuni.

Nerotiranim faktorskim rješenjem faktori se izvode prema njihovoj važnosti. Tako da je prvi faktor opći te gotovo svaka varijabla na njemu ima visoko opterećenje. Svaki sljedeći faktor objašnjava sve manji dio varijance. U ovom rješenju prvi faktor objašnjava 43,2 posto varijance među varijablama, drugi 20 posto, a treći faktor samo 10 posto varijance. Stoga je poželjno izvršiti rotiranje faktora jer se njime varijanca preraspodjeljuje s faktora koji su prvi po redu, na one kasnije. Time se dobiva jednostavnija struktura, koja se lakše tumači, a da se pri tom ne promijeni ukupna varijanca. Pored toga, u slučaju kada se rješenja faktorske analize koriste u daljnjim analizama, teorija preporuča ortogonalno rotiranje faktora¹². Kut koji zatvaraju faktorske osi dobivene ortogonalnim rotiranjem je pravi (90°), što znači da su faktori međusobno nezavisni. Pri tom se upravo *varimax* rotiranjem¹³ dobivaju rješenja koja je najlakše tumačiti. Teorija također preporuča upravo *varimax* rotiranje u slučaju kada se na temelju dobivenih faktora računaju faktorski bodovi koji služe kao ulazne varijable za daljnje analize, u ovom slučaju,

¹² Kao alternativa ortogonalnom rotiranju primjenjuje se kosokutno (*oblique*) rotiranje faktora tj. faktorskih osi. Kod kosokutnog rotiranja kutovi između faktorskih osi nisu pravi, što znači da može postojati korelacija između faktora.

¹³ Osnovne metode ortogonalnog rotiranja su *quartimax* (pojednostavljenje redaka faktorske matrice) i *varimax* rotiranje (pojednostavljenje stupaca faktorske matrice).

klaster analizu (Johnson i Wichern, 1992). Matrica faktorskih opterećenja dobivena *varimax* rotiranjem prikazana je u Tablici 5.

Tablica 5. Matrica faktorskih opterećenja nakon *varimax* rotiranja faktora

Ulazne varijable	Faktori		
	1	2	3
X1	0,71	0,21	-0,12
X2	-0,69	0,08	-0,37
X3	0,15	-0,85	0,29
X4	0,19	0,88	0,17
X5	0,15	-0,03	-0,87
X6	-0,70	-0,12	-0,53
X7	0,60	0,22	0,28
X8	-0,51	0,03	-0,70
X9	0,32	0,68	0,09
X10	0,39	-0,13	0,81
X11	0,39	0,11	0,83
Objašnjena varijanca	2,61	2,10	3,31
Proporcija objašnjene varijance	0,24	0,19	0,30

Izvor: Podaci Državnog zavoda za statistiku, Ministarstva financija, vlastiti izračuni.

Da bi se rješenje prihvatilo, potrebno je ispitati signifikantnost dobivenih faktora koji predstavljaju dimenzije društveno-gospodarskog razvoja promatranih gradova i općina.

Tri faktora, ne zadovoljavaju samo kriterij svojstvene vrijednosti, već i kriterij postotka varijance. U društvenim je znanostima donja granica prihvatljivosti 60 posto varijance objašnjene dobivenim faktorima (Hair, Anderson i Tahtam, 1987). Ovim se rješenjem objašnjava 73 posto ukupne varijance.

Varimax rotiranjem početnog rješenja dobivenog analizom glavnih komponenata dobivena su tri faktora. Prvi faktor ima visoko faktorsko opterećenje pozitivnog predznaka na varijablama: X1 (vlastiti prihodi općine po glavi stanovnika), X7 (vitalni indeks). Što znači da je pozitivno koreliran s tim obilježjima jedinica lokalne samouprave. Visoko faktorsko opterećenje negativnog predznaka prvi faktor ima s varijablom X2 (udio zaposlenih u djelatnosti Poljoprivrede i

djelatnosti Ribarstva) i X6 (koeficijent starosti). Stoga se ovaj faktor naziva *"Relativno mlado stanovništvo, gospodarski snažne jedinice lokalne samouprave, slaba zastupljenost primarnog sektora"*.

Drugi faktor ima visoko faktorsko opterećenje pozitivnog predznaka na pokazatelju postotak zaposlenih u turizmu te broj noćenja turista, a negativnog predznaka na pokazatelju udio zaposlenih u prerađivačkoj industriji. Faktor se označava kao *"Razvijeni turizam"*.

Na faktoru 3 visoka opterećenja imaju sljedeći pokazatelji. Stopa nezaposlenosti (X5), udio stanovništva bez škole (X8) s negativnim predznakom. Bruto domaći proizvod po glavi stanovnika (X10) te udio zaposlenih (X11) s pozitivnim predznakom.

Ovaj se faktor naziva *"Relativno visoka zaposlenost, kvalitetnija obrazovna struktura stanovništva i viši BDP po glavi stanovnika"*.

5. Grupiranje jedinica lokalne samouprave korištenjem klaster analize

Za grupiranje jedinica lokalne samouprave tri promatrane županije u grupe koje obilježavaju slične značajke društveno-gospodarskog razvoja korištena je klaster analiza. U društvenim je znanostima upravo klaster analiza prepoznata kao najprikladnija tehnika svrstavanja promatranih jedinica u grupe sličnih obilježja. Kao ulazne varijable za klaster analizu korišteni su faktorski bodovi. Obzirom da je kao rezultat faktorske analize dobiveno tri faktora, za svaku promatranu jedinicu lokalne samouprave izračunat će se i tri faktorska boda. Faktorski bod pokazuje stupanj u kojem svaki grad/općina ima visoki bod na grupi obilježja koje imaju visoko opterećenje na nekom faktoru. To znači da svaka jedinica lokalne samouprave koja ima visoki bod na varijablama koje imaju visoka faktorska opterećenja na nekom od tri dobivena faktora, ima i visok faktorski bod na tom faktoru. Faktorski bod pokazuje mjeru u kojoj pojedini grad/općina posjeduje obilježja prikazana faktorom.

5.1. Odabir metode klaster analize

Za svrstavanje objekata u klaster primijenjena je metoda nehijerarhijskog klasteriranja, "*k-means*" metoda¹⁴. Osnovni argument za primjenu ove metode klasteriranja je da je ovaj način grupiranja objekata u grupe pogodniji ukoliko se radi o grupiranju jedinica na kojima su izmjerena određena obilježja (objektima), a ne o grupiranju tih obilježja odnosno varijabli (Johnson i Wichern, 1992). Odluka o broju klastera zasniva se na analizi varijance (ANOVA)

5.1.1. Odluka o broju klastera – Analiza varijance

Za ovu je metodu karakteristično da se broj klastera unaprijed odredi te se testira signifikantnost dobivenog rješenja. U prvom koraku izvršen test signifikantnosti za predložena dva klastera. Test signifikantnosti u ANOVA-i ispituje varijabilnost između grupe s varijabilnošću unutar grupa kada se testira hipoteza da se sredine između grupa međusobno razlikuju¹⁵. Uz teorijsku razinu signifikantnosti od 5 posto, rezultati ANOVA-e za dva (2) predložena klastera nisu signifikantni. Naime s obzirom da je na drugom faktoru empirijska *p* vrijednost veća od teorijske ($p=0,07>0,05$), hipoteza¹⁶ H_1 se mora odbaciti što znači da se sredine između grupa signifikantno ne razlikuju (vidi Tablica 6. Rezultati ANOVA-e za dva klastera). Ne može prihvatiti rješenje kojim se promatrane jedinice lokalne samouprave grupiraju u dva klastera.

¹⁴ Dva osnovna pristupa klaster analizi su hijerarhijska klaster analiza i nehijerarhijska klaster analiza.

¹⁵ Zapravo se radi o analizi varijance u obrnutom smjeru. Analiza varijance podrazumijeva testiranje hipoteze o jednakosti aritmetičkih sredina više osnovnih skupova.

¹⁶ H_1 hipotezom se tvrdi da se sredine između klastera na svakoj dimenziji (faktoru) signifikantno razlikuju. Alternativnom, nultom hipotezom (H_0) se tvrdi da su sredine klastera jednake.

Tablica 6. Rezultati ANOVA-e za dva predložena klastera						
Faktor	Sredine između klastera	s.s.	Sredine unutar klastera	s.s.	F omjer	p-vrijednost
Faktor1	17,19	1	67,81	84	21,30	0,000014
Faktor2	3,39	1	81,62	84	3,48	0,065458
Faktor3	30,30	1	54,70	84	46,53	0,000000

Izvor: Podaci Državnog zavoda za statistiku, Ministarstva financija, vlastiti izračuni.


Stoga se prelazi na sljedeći korak te se vrši test signifikantnosti u ANOVA-i za tri (3) klastera. Uz danu razinu signifikantnosti od 5 posto, i empirijske razine signifikantnosti od 0,001627 za prvi faktor, 0,0000 za drugi i 0,0000 za treći faktor prihvaća se H1 hipoteza odnosno može se tvrditi da se sredine između tri predložena klastera signifikantno razlikuju. (vidi Tablica 7. Rezultati ANOVA-e za tri klastera).

Tablica 7. Rezultati ANOVA-e za tri predložena klastera						
Varijabla	Sredine između klastera	s.s.	Sredine unutar klastera	s.s.	Empirijski F omjer	p -vrijednost
Faktor1	12,18	2	72,82	83	6,9445	0,001627
Faktor2	61,21	2	23,79	83	106,7699	0,000000
Faktor3	44,52	2	40,48	83	45,6396	0,000000

Izvor: Podaci Državnog zavoda za statistiku, Ministarstva financija, vlastiti izračuni.

Rezultati koji ukazuju na grupiranje jedinica lokalne samouprave u tri različita klastera su signifikantni. Cilj koji se trebao postići je da se sredine koju svaki klaster ima na pojedinoj dimenziji signifikantno razlikuju. Kako test signifikantnosti proveden ANOVA-om to potvrđuje, isto se može provjeriti promotri li se graf odnosa faktora odnosno faktorskom analizom utvrđenih dimenzija društveno-gospodarskog razvoja te sredina pojedinog klastera. (Vidi Slika 1.)

Slika 1. Sredina svakog klastera



Izvor: Podaci Državnog zavoda za statistiku, Ministarstva financija, vlastiti izračuni.

5.2. Identificirane homogene prostorno-gospodarske cjeline

Iz grafa se mogu iščitati razlike koje postoje među klasterima odnosno specifičnosti svakog klastera. Najizraženija su obilježja društveno-gospodarskog razvoja prvog klastera, koji se po sve tri promatrane dimenzije razlikuje od preostala dva klastera. Nasuprot tome, drugi i treći klaster su gotovo jednaki s obzirom na obilježja društveno-gospodarskog razvoja koja predstavljaju 1. i 3. faktor, ali se značajno razlikuju s obzirom na obilježje društveno-gospodarskog razvoja kojeg prezentira 2. faktor.

Prvi klaster karakterizira jaka negativna veza s trećim faktorom bodom koji označava visoku zaposlenost, visoki BDP po glavi stanovnika. Također postoji negativna veza s prvim faktorom što ukazuje na veliku zastupljenost primarnog

sektora i prevladavajuće stanovništvo starije dobi, relativno neobrazovano. Ovu grupu sačinjava samo sedam jedinica lokalne samouprave koje se nalaze isključivo u Ličko-senjskoj županiji. To su grad Gospić, općine Donji Lapac, Lovinac, Perušić, Plitvička jezera, Vrhovine i Udbina¹⁷. Ovaj klaster se može nazvati *Grupa jedinica lokalne samouprave sa slabim gospodarskim potencijalom*.

Drugi klaster sačinjava čak pedeset i četiri (54) jedinica lokalne samouprave. U ovoj je grupi gradova/općina najzastupljenije obilježje koje prezentira drugi faktor, a to je prevladavajući sekundarni sektor u strukturi gospodarstva te nerazvijen turizam¹⁸. Obzirom na slabu, no ipak pozitivnu vezu s trećim faktorom, ovoj se grupi općina može i pripisati obilježje nepostojanja značajnijeg problema zaposlenosti usporedbi s prvim klasterom gdje je taj problem najizraženiji¹⁹. Ovaj se klaster može označiti kao grupa jedinica lokalne samouprave s *prevladavajućim sekundarnim sektorom u strukturi gospodarstva*. U Istarskoj županiji ovom klasteru pripadaju sljedeće jedinice lokalne samouprave: gradovi Buje, Buzet, Labin, Pazin, Pula, Vodnjan te općine Bale, Barban, Brtonigla, Cerovlje, Fažana, Gračišće, Grožnjan, Kanfanar, Karojba, Kršan, Lanišće, Ližnjan, Lupoglav, Marčana, Motovun, Oprtalj, Pićan, Raša, Sveta Nedjelja, Sveti Petar u Šumi, Svetvinčenat, Tinjan, Žminj. Gradovi i općine iz Primorsko-goranske županije koji pripadaju ovom klasteru su: Bakar, Čabar, Delnice, Kastav, Kraljevica, Rijeka, Vrbovsko, Brod Moravice, Čavle, Fužine, Jelenje, Klana, Kostrena, Lokve, Matulji, Mrkopalj, Omišalj, Ravna Gora, Skrad, Vinodolska općina, Viškovo, Vrbnik. Gradovi Otočac i Senj te općina Brinje jedinice su lokalne samouprave iz Ličko-senjske županije koje također nose obilježja tog klastera.

Treći klaster sačinjava 25 gradova i općina. To su redom jedinice lokalne samouprave smještene u priobalnom području. U Istarskoj županiji to su gradovi

¹⁷ Spomenute općine pripadaju Području posebne državne skrbi.

¹⁸ Karakteristična je snažna negativna veza s drugim faktorskim bodom, koji prezentira obilježja drugog faktora, a to su razvijen turizam i mala zastupljenost djelatnosti Prerađivačke industrije. Budući da je veza negativna, tumači se kao veća zastupljenost sekundarnog sektora u strukturi gospodarstva te nerazvijen turizam.

¹⁹ Bitno je napomenuti da je riječ o problemu nezaposlenosti u relativnom smislu s obzirom da je kao takav prisutan u gospodarstvu ne samo promatranih JLS-a, već i u čitavoj zemlji. Stoga se pojam nepostojanja značajnijeg problema nezaposlenosti odnosi na usporedbu s istim u preostalim klasterima (osobito prvim klasterom).

Novigrad, Poreč, Rovinj, Umag te općine Kaštelir-Labinci, Medulin, Sveti Lovreč, Višnjan, Vižinada i Vrsar. U Ličko-senjskoj županiji to su Karlobag i Novalja. Trinaest gradova i općina iz Primorsko-goranske županije pripada ovom klasteru. To su Baška, Cres, Crikvenica, Dobrinj, Krk, Lovran, Mali Lošinj, Malinska-Dubašnica, Mošćenička Draga, Novi Vinodolski, Opatija, Punat i Rab. Kao što se može i pretpostaviti, obzirom na geografski položaj tih jedinica lokalne samouprave, ovaj klaster ima najizraženija obilježja koja prezentira drugi faktor. Gospodarska djelatnost koja prevladava u ovom klasteru je turizam, a također u ovom je klasteru u usporedbi s ostalima najmanje izražen problem nezaposlenosti odnosno najveća je zaposlenost stanovništva. Stoga se ovaj klaster naziva grupa jedinica lokalne samouprave s *izrazito turističkom gospodarskom orijentacijom te relativno visokom zaposlenošću stanovništva*.

6. Zaključak

Mjere regionalne politike dovode do željenih i jednakih učinaka na nekom prostoru samo ako se provode na prostornim jedinicama koje su homogene s obzirom na obilježja društvenog i gospodarskog razvoja. Budući da su primjenom metoda faktorske i klaster analize izdvojene jedinice lokalne samouprave sličnih obilježja koje su predmet instrumenata i mjera regionalne politike potvrđena je osnovna hipoteza rada.

Sljedeći zaključak je da udaljenost između pojedinih prostornih jedinica, u ovom slučaju gradova i općina, ne mora nužno podrazumijevati i „udaljenost“ odnosno različitost s obzirom na obilježja društveno-gospodarskog razvoja tih prostornih jedinica. Tako na primjer, grad Pula, te općine Ližnjan i Vodnjan, unatoč tome što se nalaze uz obalu, kao i većina jedinica iz trećeg klastera, ne pripadaju tom, već drugom klasteru. Isti je slučaj s općinom Vižinada, koja se nalazi u unutrašnjosti Istre te je uglavnom okružena jedinicama lokalne samouprave koje formiraju drugi klaster, a sama pripada trećem klasteru.

Ovim se radom omogućuje sagledavanje u hrvatskoj praksi novih pristupa klasifikacije prostora u homogenije jedinice radi formuliranja mjera regionalne

Literatura

Čižmešija, M. i N. Kurnoga Živadinović, 2002, "Faktorska analiza rezultata konjunkturnih testova Hrvatske", *Ekonomski pregled*, (7-8), str. 684-704.

Ding, C. G i F. M. Liou, 2002, "Subgrouping Small States Based on Socioeconomic Characteristics", *World Development*, 30(7), str. 1289-1306.

Državni zavod za statistiku, 2002, *Statistički ljetopis 2002*.

Državni zavod za statistiku, 2002, *Statističko izvješće "Zaposlenost i plaće" 1162/2002*.

Državni zavod za statistiku, 2002, *Statističko izvješće „Turizam“ 1176/2002*.

Državni zavod za statistiku, 2002, *Popis stanovništva, kućanstava i stanova 31. ožujka 2001*, <http://www.dzs.hr/Popis%202001/popis20001.htm>.

EUROSTAT, 2003, EUROSTAT European Regional Statistics – Reference Guide 2003, http://www.eu-datashop.de/download/DE/klasifi/ncronos/thema1/reg_guid.pdf.

Fulgosi, A., 1988, *Faktorska analiza*, Zagreb, Školska knjiga.

Gaur, S., 1997, "Adelman and Morris Factor Analysis of Developing countries", *Journal of Policy Modeling* 19 (4), str. 407-415.

General provisions on the Structural Funds,
<http://europa.eu.int/scadplus/leg/en/lvb/l60014.htm>.

Gilbert, A. i A. G. Churchill, 1995, *Marketing Research - Methodological Foundations*, Dryden Press: Fort Worth, TX.

Hair, F. J., E. R. Anderson i L. R. Tahtam, 1987, *Multivariate Data Analysis*, New York: Macmillan Publishing Company.

Johnson, A. R. i W. D. Wichern, 1992, *Applied Multivariate Stastical Analysis*, 3rd Ed., New York, Upper Saddle River: Prentice Hall.

Kinnear, P. i C. D. Gray, 1994, *SPSS for Windows Made Simple*, Hove, UK: Lawrence Erlbaum Associates Publishers.

Kronthaler, F., 2003, "A Study of Competitiveness of Regions based on a Cluster Analysis: The Example of East Germany", referat na konferenciji "Peripheries, centres, and spatial development in the new Europe", u organizaciji European Regional Science Association (ERSA), Jyväskylä, kolovoz.

Lipshitz, G. i A. Raveh, A., 1998, "Socio-economic Differencies among Localities: A New Method of Multivariate Analysis", *Regional Studies Journal of the Regional Studies Association*, 32 (8), str. 747-758.

Loedwijk, B. i D. Terweduwe, 1988, "The Classification of Countries by Cluster and by Factor Analysis", *World Development*, 16(12), str. 1527-1545.

Marinović-Uzelac, A., 2001, *Prostorno planiranje*, Zagreb: Dom i svijet.

Ministarstvo financija, 2001, *Proračuni jedinica lokalne samouprave Istarske županije za 2001. godinu*, <http://www.mfin.hr/lokalna/2001/zup18.htm>.

Ministarstvo financija, 2001, *Proračuni jedinica lokalne samouprave Ličko-senjske županije za 2001. godinu*, <http://www.mfin.hr/lokalna/2001/zup09.htm>.

Ministarstvo financija, 2001, *Proračuni jedinica lokalne samouprave Primorsko-goranske županije za 2001. godinu*, <http://www.mfin.hr/lokalna/2001/zup08.htm>.

Morrison, F. D., 1987, *Multivariate Statistical Methods*, New York: McGraw-Hill Book Co.

Narodne novine, različita godišta.

Punj, G. i D. W. Stewart, D.W., 1983, "Cluster analysis in marketing research; a review and suggestions for application", *Journal of Marketing Resaerch*, 20, str. 134-148.

Rašić, I., 2003, "Introduction of Nomenclature of Territorial Units for Statistics in Croatia", Institute of Economics, Zagreb, referat na konferenciji "Peripheries, centres, and spatial development in the new Europe", u organizaciji European Regional Science Association (ERSA), Jyväskylä, kolovoz.

Starc, N. (ured.), 2003, „Analiza gospodarstva u područjima posebne državne skrbi“, Zagreb: Ekonomski institut, dokumentacija.

STATISTICA, 1999, Program Overview, StatSoft.

Šošić, I. i V. Serdar, 1992, *Uvod u statistiku*, Zagreb, Školska knjiga.

Ward, J., 1963, "Hierarchical grouping to optimize an objective function", *Journal of American Statistical Association*, 58, 236-244.

Wertheimer-Baletić, A., 1999, *Stanovništvo i razvoj*, Zagreb: MATE.