MULTIVARIJACIJSKA ANALIZA ZEMALJA EU-28 PREMA NJIHOVIM DEMOGRAFSKIM ZNAČAJKAMA U 2015. GODINI

Radoš, Danijela

Master's thesis / Diplomski rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of economics Split / Sveučilište u Splitu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:333535

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET SPLIT

DIPLOMSKI RAD

MULTIVARIJACIJSKA ANALIZA ZEMALJA EU-28 PREMA NJIHOVIM DEMOGRAFSKIM ZNAČAJKAMA U 2015. GODINI

Mentor:

Prof. dr. sc. Elza Jurun

Student:

Danijela Radoš, bacc. oec.

Br. indeksa: 2150689

Split, rujan 2017.

SADRŽAJ:

1. UVOD ……... 4

1.1. Problem istraživanja ……... 4

1.2. Predmet istraživanja ……... 5

1.3. Istraživačke hipoteze ……... 6

1.4. Ciljevi istraživanja ……... 6

1.5. Metode istraživanja ……. 7

1.6. Doprinos istraživanja …….. 9

1.7. Struktura rada ……. 10

2. EUROPSKA UNIJA ……... 11

2.1. Razvoj Europske unije ……... 11

2.2. Članstvo u Europskoj uniji ……. 12

2.2.1. Kriteriji za članstvo u Europskoj uniji ……. 12

2.2.2. Države članice Europske unije ……. 13

2.2.3. Države kandidati Europske unije ……. 13

2.2.4. Države potencijalni kandidati Europske unije ……. 14

2.3. Simboli Europske unije ……... 14

3. DEMOGRAFIJA I DEMOGRAFSKA STATISTIKA ……... 15

3.1. Demografija ……. 15

3.2. Demografska statistika ……. 16

3.2.1. Stanovništvo kao varijabla demografske statistike ……. 17

3.2.2. Izvori podataka o stanovništvu ……. 19

3.3. Temeljni demografski pokazatelji ……. 19

3.3.1. Pokazatelji promjena u ukupnom broju stanovnika ……. 19

3.3.2. Ukupno kretanje stanovništva ……...……...……... 21

3.3.3. Komponente prirodnog kretanja stanovništva ……...…..….. 21

4. METODE KLASIFICIRANJA …….……..…… 26

4.1. Multivarijacijska Cluster analiza ……..…….. 26

4.1.1. Hijerarhijske metode …….…….... 27

4.1.2. Nehijerarhijske metode ……..…….……... 29

4.1.3. K-means metoda ……..…...……... 30

5. MULTIVARIJACIJSKA ANALIZA ZEMALJA EU-28 PREMA NJIHOVIM DEMOGRAFSKIM ZNAČAJKAMA U 2015. GODINI …….…….…..…… 32

5.1. Kriteriji klasificiranja …….…….……. 32

5.2. Metodologija klasificiranja ……..……. 33

5.2.1. Klasificiranje u 15 klastera ……..…….. 33

5.2.2. Klasificiranje u 14 klastera …….…….…….. 36

5.2.3. Klasificiranje u 13 klastera …….…….. 38

5.2.4. Klasificiranje u 12 klastera …….…….. 40

5.2.5. Klasificiranje u 11 klastera …….…….. 42

5.2.6. Klasificiranje u 10 klastera …….…….. 44

5.2.7. Klasificiranje u 8 klastera …….. 46

5.2.8. Klasificiranje u 6 klastera ……..……..…….. 48

5.2.9. Klasificiranje u 9 klastera ……..……..…….. 50

5.2.9.1. Klasificiranje u 9 klastera hijerarhijskom metodom ……...…….. 51

5.2.9.2. Klasificiranje u 9 klastera nehijerarhijskom metodom …….…… 56

6. ZAKLJUČAK …….……..……..…… 63

POPIS SLIKA

POPIS TABLICA

LITERATURA

SAŽETAK

SUMMARY

1. UVOD

1.1. Problem istraživanja

Problem istraživanja u ovom diplomskom radu su različite demografske značajke koje u znatnoj mjeri utječu na socijalnu politiku koja podrazumijeva državnu preraspodjelu nacionalnog dohotka usmjerenu na prevladavanje socijalnih rizika, smanjenje socijalnih nejednakosti, te ujednačavanje životnih uvjeta građana.

Treba izdvojiti četiri socijalno-demografska čimbenika koji djeluju na gospodarske i socijalne prilike pa, shodno tome, i na socijalnu politiku. Prvo, radi se o opadanju fertiliteta, odnosno smanjenju stopa biološke reprodukcije stanovništva. Drugo, opadanje fertiliteta povezano je s demografskim starenjem koje podrazumijeva povećanje udjela starijeg stanovništva u ukupnom stanovništvu. Na trećem su mjestu migracije stanovništva, kako unutrašnje, tako i vanjske, koje poprimaju sve veće razmjere. Četvrto je proces transformacija strukture i funkcija obitelji.[1]

Tijekom druge polovice 20. stoljeća svijet je prošao kroz jedinstveno razdoblje u povijesti stanovništva, u kojem je završen proces demografske tranzicije u razvijenim zemljama. U novonastalim gospodarskim, zdravstvenim i društvenim prilikama, tip (režim) reprodukcije stanovništva obilježava nizak i opadajući natalitet/fertilitet i mortalitet, tako da prirodni prirast stanovništva pokazuje izrazitu tendenciju prema nultoj razini.[2]

Istodobno je snažno ubrzan proces starenja stanovništva kao odraz dugotrajnog snižavanja stope nataliteta i produženja ljudskog vijeka (očekivanog trajanja života) vezanog uz brojna medicinska otkrića i zdravstvena postignuća. Tako su posljednjeg desetljeća 20. stoljeća, demografske promjene u razvijenim, prvenstveno zapadno europskim zemljama, bitno obilježila dva međusobno usko povezana demografska procesa - depopulacija i starenje stanovništva.

[1] Puljiz, V. (2016): Starenje stanovništva–izazov socijalne politike, Revija za socijalnu politiku, 23(1), str. 81-98.
[2] Wertheimer-Baletić, A. (2005): Populacijska politika u razvijenim europskim zemljama, Rad Hrvatske akademije znanosti i umjetnosti, str. 297.

Europska unija se danas suočava s najvećim nekontroliranim priljevom migranata i izbjeglica u svojoj povijesti tako da se slobodno može govoriti o migracijskoj i izbjegličkoj krizi. Uzroci koji su doveli do eksplozije migrantske krize u 2015. godini su različiti. Među najznačajnijim ubrajamo bijeg od ratnih stradanja, potraga za boljim životom, odlazak iz nefunkcionalnih država te bijeg od različitih vidova ekstremizma i terorizma. Procjenjuje se kako je 2000. godine bilo oko 150 milijuna migranata u svijetu, deset godina kasnije 214 milijuna uz pretpostavku rasta na 405 milijuna do 2050. godine.[3]

Glavni tokovi migracija usmjereni su prema visokorazvijenim zemljama i područjima gdje Europska unija unatrag nekoliko godina predstavlja najpoželjniju, ali i najlakše dostižnu destinaciju. Ostale ciljne države, prije svega SAD, Kanada i Australija mnogima su migrantima nedostižne zbog velikih udaljenosti i pojačanih kontrola na njihovim granicama.

Ogroman, te prije svega nekontroliran priljev migranata u 2014. i 2015. godini u Europsku uniju, neovisno o poduzetim mjerama i pravnim ograničenjima, učinio je ustupak da se to pitanje, kao i pitanje nadzora i sigurnosti granice, pozicionira u žarište zaštite nacionalnih interesa određenih država. Tako se pitanje unutarnje sigurnosti nekih država danas povezuje s migrantima, to jest s njihovim nekontroliranim priljevom i mogućim utjecajem na sigurnosno, ekonomsko i političko stanje u državi.

1.2. Predmet istraživanja

Na temelju prethodno navedenog i opisanog problema, moguće je formulirati predmet istraživanja rada kao teorijska i empirijska analiza demografskih i statističkih pokazatelja prema popisima stanovništva Europske unije.

Proučavane su sve demografske značajke zemalja EU-28 koje prati njihova službena statistika i to u svim promatranim zemljama. Stoga je istraživanje provedeno na temelju 9 demografskih varijabli, pokazatelja na razini promatranih država članica Europske unije. A to su: broj rođenih, broj umrlih, imigracije, BDP per capita, fertilitet, godine zavisnosti mladog stanovništva, godine zavisnosti starog stanovništva, tražitelji azila, te stopa zaposlenosti.

[3] Tadić, J., Dragović, F., Tadić, T. (2016): Migracijska i izbjeglička kriza–sigurnosni rizici za EU, Policija i sigurnost, 25(1/2016), str. 14-42.

Svi korišteni podaci preuzeti su sa Eurostata, te se odnose na 2015. godinu, koja je trenutno najkasnija godina za koju su poznati i dostupni podaci za sve zemlje Europske unije.

U obzir su uzete demografske varijable koje najznačajnije utječu na gospodarske i socijalne probleme, a samim time i na način provođenja aktivne demografske politike. Trenutna demografska politika odgovor je na demografske promjene s kojima se suočava Europa, a to su smanjenje stope nataliteta, starenje stanovništva i veliki migracijski tokovi.

1.3. Istraživačke hipoteze

U skladu sa prethodno navedenim i opisanim problemima i predmetom istraživanja, postavljene su i odgovarajuće hipoteze koje treba prihvatiti ili odbaciti:

H_1 - zemlje EU-28 se po demografskim pokazateljima mogu svrstati u manji broj klastera

H_2 - većina zemalja osnivačica EU s obzirom na demografske pokazatelje izdvaja se u posebne klastere

H_3 - zemlje s najvišim BDP-om po stanovniku izdvajaju se u zasebne klastere

H_4 - tražitelji azila preferiraju zemlje EU-28 koje se nalaze u samo nekoliko klastera formiranih na temelju njihovih demografskih karakteristika

1.4. Ciljevi istraživanja

Na temelju formiranih hipoteza, kao i predmeta i problema istraživanja, glavni cilj je grupiranje zemalja članica Europske unije u homogene grupe (klastere) s obzirom na njihova demografska obilježja.

Analizom nepovoljnih karakteristika demografskih procesa ovim radom se želi ukazati na goruće demografske probleme i to s naglaskom na područje zemalja članica Europske unije.

Cilj ovoga rada je i stvaranje kvalitetnog analitičkog temelja za prijedlog odgovarajućih mjera populacijske politike s elementima pronatalitetne i redistribucijske politike razvoja pučanstva.

1.5. Metode istraživanja

Kako bi ovaj rad putem teorijskog istraživanja dao odgovor na postavljene hipoteze i ciljeve, koristit će se odgovarajuće znanstvene metode:[4]

- Metoda deskripcije - postupak jednostavnog opisivanja činjenica, procesa i predmeta u prirodi i društvu te empirijskih potvrđivanja odnosa i veza. Ova metoda se primjenjuje u početnoj fazi istraživanja te zahtjeva primjenu tehnika promatranja kao glavnog načina prikupljanja podataka.
- Metoda klasifikacije - sistematska i potpuna podjela općeg pojma na posebne, koje taj pojam obuhvaća.
- Metoda prikupljanja podataka - u radu će se koristiti sekundarni podaci iz knjiga, stručnih i znanstvenih časopisa, međunarodnih publikacija, provedenih istraživanja te internetskih stranica.
- Metoda kompilacije - postupak preuzimanja tuđih rezultata znanstvenoistraživačkog rada, odnosno tuđih opažanja, stavova, zaključaka i spoznaja.
- Metoda komparacije - postupak uspoređivanja istih ili srodnih pojava te utvrđivanje njihovih međusobnih sličnosti u ponašanju i intenzitetu te razlika.
- Metoda analize i sinteze - metoda analize je raščlanjivanje složenih pojmova, sudova i zaključaka na njihove jednostavnije sastavne dijelove te izučavanje svakog dijela posebno i u odnosu na druge dijelove, dok je sinteza postupak znanstvenog istraživanja i objašnjavanja stvarnosti putem sinteze jednostavnih sudova u složenije.
- Metoda indukcije i dedukcije - dedukcija je definirana kao zaključivanje od općeg prema posebnom, dok je indukcija zaključivanje od posebnog prema općem.

[4] Zelenika, R. (2000): Metodologija i tehnologija izrade znanstvenog i stručnog djela, 4. izdanje, Ekonomski fakultet u Rijeci, Rijeka.

Uz navedene znanstvene metode, u empirijskom dijelu će se koristiti i sljedeće statističke metode:

- Relativni brojevi - Statistička analiza može se provesti na temelju apsolutnih ili relativnih veličina. Apsolutne veličine ili apsolutni brojevi ne mogu uvijek zadovoljiti svrhu statističke analize, pogotovo kada se radi o velikim brojevima, odnosno značajnim frekvencijama statističkog niza. Za razliku od apsolutnih brojeva, relativnim se brojevima mogu uspoređivati pojave koje imaju različite jedinice mjere ili različiti broj elemenata. Relativni brojevi mogu biti: *relativni brojevi strukture, relativni brojevi koordinacije i indeksi.*

  Relativni brojevi strukture su proporcije i pokazuju odnos dijela prema cjelini. Mogu se izraziti u postotcima ili u promilima. Relativni brojevi koordinacije pokazuju odnos dviju pojava ili odgovarajućih frekvencija u različitim statističkim nizovima, koji mogu biti potpuno neizvjesni jedan od drugog. Te pojave mogu imati istu ili različitu jedinicu mjere. Indeksi ili indeksni brojevi su relativni brojevi kojima se uspoređuju smjer i intenzitet varijacija frekvencija nekog statističkog niza s takvim varijacijama drugoga statističkoga niza. Kao baza uzima se određena veličina iz statističkog niza da bi se sve druge veličine stavile u odnos s njom. [5]

  Relativni brojevi koordinacije su vrsta relativnih ili omjernih brojeva koji se dobiju stavljanjem u omjer dviju koordinirajućih pojava. Pri tome je važno da je dobiveni omjer smislen, odnosno da ima logičnu interpretaciju.[6]

  Indeksi spadaju u relativne pokazatelje dinamike. Indeksima se uspoređuje stanje jedne pojave ili skupine pojava u različitim vremenskim intervalima ili momentima ili na različitim mjestima. Razlikujemo individualne i skupne indekse. Individualnim indeksima mjerimo dinamiku svake pojave pojedinačno, dok se skupnim indeksima mjeri dinamika skupine pojava koje obično imaju neku zajedničku karakteristiku koja ih povezuje u skupinu. Među individualne indekse ubrajamo verižne indekse (pokazuju relativne promjene pojava u tekućem razdoblju u odnosu na prethodno razdoblje) i bazne indekse (pokazuju relativne promjene u tekućem razdoblju u odnosu

[5] Rozga, A. (2009): Statistika za ekonomiste, Ekonomski fakultet, Split.
[6] Rozga, A., Grčić B. (2009): Poslovna statistika, Ekonomski fakultet, Split.

na odabrano bazno razdoblje; prigodom izbora baznog razdoblja treba biti vrlo obazriv jer se krivim izborom baznog razdoblja mogu dobiti pogrešne predodžbe o dinamici pojave).[7]

- Stope – pojam stopa ima široku primjenu. Demografski pokazatelji koji se nazivaju stopama često su ustvari proporcije (pokazuje veličinu podskupine stanovništva u odnosu na čitavu populaciju), koeficijenti (umjesto opisivanja veličine neke podskupine u odnosu na čitavu populaciju, opisuje veličinu određene podskupine u odnosu na drugu podskupinu) ili složenije mjere. Strogo gledano, stopa je mjera promjene u populaciji u određenom vremenskom razdoblju (obično godišnje). Pri izračunu stope brojnik je broj događanja od interesa (rođenih, umrlih, vjenčanih…) koji se javljaju tijekom određenog vremenskog razdoblja. Nazivnici su najčešće broj osoba ili godina za koje se vrši procjena. [8]

- Cluster analiza – vrsta multivarijacijske statističke analize koja spada u metode klasificiranja- Temelji se na matematički formuliranim mjerama sličnosti i obuhvaća različite postupke, algoritme i metode grupiranja podataka.[9]

1.6. Doprinos istraživanja

Istraživanja provedena u ovom radu mogu biti motiv državama članicama, sa sličnim karakteristikama, da usuglase zajedničke mjere aktivne demografske politike.

S obzirom da se populacijska politika provodi na temelju postavljenih ciljeva koji se žele ostvariti, rezultati dobiveni u ovom radu mogu služiti kao smjernice za postavljanja tih ciljeva, a na kraju i za donošenje odgovarajućih mjera populacijske politike s elementima pronatalitetne i redistribucijske politike razvoja pučanstva.

Također, istraživanje bi trebalo proširiti spoznaju o utjecaju demografskih čimbenika na strukturu i razvoj kulturne, političke i socio-ekonomske sfere društva kao i na način i kvalitetu života općenito.

[7] Ibid.
[8] Rozga, A. (2009): Statistika za ekonomiste, Ekonomski fakultet, Split.
[9] Pivac, S. (2010): Statističke metode, Ekonomski fakultet u Splitu, Split.

1.7. Struktura rada

Nakon što je **uvodni dio** rada predstavio predmet istraživanja, temeljne probleme istraživanja kao i ciljeve, metode i strukturu rada, u **drugom dijelu** rada upoznat ćemo se sa značajkama Europske unije.

Treći dio rada posvećen je teorijskim demografskim i statističkim postavkama. Obrađene su i temeljne demografske spoznaje relevantne za predmet istraživanja i popraćene uobičajenim demografskim pokazateljima.

U **četvrtom dijelu** rada objašnjene su metode klasificiranja s posebnim naglaskom na Cluster analizu, pomoću koje se u **petom dijelu** rada vrši empirijsko istraživanje i testiranje postavljenih hipoteza, na temelju demografskih varijabli zemalja članica Europske unije.

Na kraju se iznose zaključci i popis korištene literature.

2. EUROPSKA UNIJA

2.1. Razvoj Europske unije

Europska unija jedinstvena je gospodarska i politička unija 28 europskih država koje zajedno pokrivaju velik dio kontinenta.[10]

Europska unija osnovana je nakon Drugog svjetskog rata. Sve je počelo poticanjem gospodarske suradnje. Vjerovalo se da će zemlje koje međusobno trguju postati gospodarski ovisne jedna o drugoj i zbog toga vjerojatno izbjegavati sukobe.

Tako je 1958. nastala Europska ekonomska zajednica (EEZ), u okviru koje je u početku pojačana gospodarska suradnja šest zemalja: Belgije, Njemačke, Francuske, Italije, Luksemburga i Nizozemske. Otada je stvoreno golemo jedinstveno tržište, koje se i dalje razvija kako bi doseglo svoj puni potencijal.

Ono što je započelo kao isključivo gospodarska unija razvilo se u organizaciju koja obuhvaća brojna područja politika, od klimatskih pitanja, zaštite okoliša i zdravstva do vanjskih poslova i sigurnosti, te pravosuđa i migracija. To se odrazilo u promjeni imena iz Europske ekonomske zajednice (EEZ) u Europsku uniju (EU) 1993. godine.

Europska unija formalno je uspostavljena 1. studenoga 1993. godine stupanjem na snagu Ugovora o Europskoj uniji (poznatiji kao Ugovor iz Maastrichta).

U Europskoj uniji već više od pola stoljeća vladaju mir, stabilnost i blagostanje, poboljšan je životni standard i uvedena je jedinstvena europska valuta: euro. Za promicanje mira, pomirenja, demokracije i ljudskih prava u Europi, EU-u je 2012. dodijeljena Nobelova nagrada za mir.

Zahvaljujući ukidanju graničnih kontrola među državama članicama EU-a ljudi mogu slobodno putovati gotovo čitavim kontinentom. Ujedno je postalo mnogo jednostavnije živjeti, raditi i putovati u inozemstvu unutar Europe.

Jedinstveno ili „unutarnje" tržište glavni je gospodarski pokretač EU-a, koji omogućuje slobodno kretanje većine robe, usluga, novca i osoba. Drugi je ključni cilj razvijanje tog

[10] Službena web stranica Europske unije: https://europa.eu/european-union/about-eu/eu-in-brief_hr (27.06.2017.)

golemog resursa i u drugim područjima poput tržišta energije, znanja i kapitala kako bi Europljani od njega imali što veću korist.

2.2. Članstvo u Europskoj uniji

2.2.1. Kriteriji za članstvo u Europskoj uniji

Člankom 49 Lisabonskog ugovora, svaka europska država, čije uređenje počiva na načelima slobode, demokracije, poštivanja ljudskih prava i temeljnih sloboda, te vladavine prava, može podnijeti zahtjev za članstvo u Uniji. Na sastanku Europskog vijeća 1993. godine u Kopenhagenu definirana su 3 kriterija (tzv. Kriteriji iz Kopenhagena ili Kopenhaški kriteriji) koja mora ispunjavati svaka država koja želi postati punopravnom članicom Europske unije. To su: [11]

- **politički**: stabilnost institucija koje osiguravaju demokraciju, vladavinu prava, poštivanje ljudskih prava i prava manjina i prihvaćanje političkih ciljeva Unije;
- **gospodarski**: postojanje djelotvornog tržišnog gospodarstva te sposobnost tržišnih čimbenika da se nose s konkurentskim pritiscima i tržišnim zakonitostima unutar Europske unije;
- **pravni**: usvajanje cjelokupne pravne stečevine Europske unije.

Kako bi se osigurala uspješna provedba prihvaćene pravne stečevine Europske unije, na zasjedanju Europskog vijeća u Madridu, u prosincu 1995. godine, zaključeno je da provedbu svih reformi (političkih, gospodarskih i pravnih) nužno mora pratiti i odgovarajuće administrativno ustrojstvo, te je uspostavljen i četvrti, Madridski kriterij, kao preduvjet za članstvo:[12]

- **administrativni:** prilagodba odgovarajućih administrativnih struktura s ciljem osiguravanja uvjeta za postupnu i skladnu integraciju (kao što su jačanje administrativne sposobnosti, stvaranje učinkovitog sustava državne uprave s ciljem osiguravanja učinkovitog procesa usvajanja i provedbe pravne stečevine Europske unije).

[11] Ministarstvo vanjskih i europskih poslova RH, http://www.mvep.hr/hr/ (27.06.2017.)
[12] Ibid.

2.2.2. Države članice Europske unije

Države članice Europske unije su: Austrija, Belgija, Bugarska, Cipar, Češka, Danska, Estonija, Finska, Francuska, Grčka, Hrvatska, Irska, Italija, Litva, Latvija, Luksemburg, Mađarska, Malta, Nizozemska, Njemačka, Poljska, Portugal, Rumunjska, Slovačka, Slovenija, Španjolska, Švedska i Ujedinjeno Kraljevstvo[13].



Slika 1: Zemlje članice Europske unije

Izvor: https://europa.eu/european-union/about-eu/countries_hr

2.2.3. Države kandidati Europske unije

Među države kandidate, odnosno zemlje koje su u postupku prenošenja (tj. integriranja) zakonodavstva EU-a u nacionalno ubrajamo: Crnu Goru, Makedoniju, Srbiju, Tursku i Albaniju.

[13] U Ujedinjenom Kraljevstvu 23. lipnja 2016. održan je referendum o tome treba li ona ostati u Europskoj uniji (tzv. Brexit). Ujedinjeno Kraljevstvo obavijestilo je Europsko vijeće 29. ožujka 2017. o tome da namjerava napustiti EU, čime je službeno pokrenut postupak predviđen člankom 50. Ugovora o Europskoj uniji.

2.2.4. Države potencijalni kandidati Europske unije

Potencijalne države kandidatkinje koje još ne ispunjavaju uvjete za članstvo u EU-u su Bosna i Hercegovina, te Kosovo.

2.3. Simboli Europske unije

- **Europska zastava -** Europska zastava simbolizira ne samo Europsku uniju već i europsko jedinstvo i identitet u širem smislu. Europska zastava sastoji se od kruga od 12 zlatnih zvijezda na plavoj podlozi. Zvijezde simboliziraju ideale jedinstva, solidarnosti i sklada među narodima Europe. Broj zvijezda nije povezan s brojem država članica, dok krug simbolizira jedinstvo.

- **Europska himna -** Melodija koja simbolizira EU potječe iz Devete simfonije koju je skladao Ludwig Van Beethoven. Njome je uglazbio „Odu radosti", lirsku pjesmu Friedrichavon. Himna simbolizira ne samo Europsku uniju već i Europu u širem smislu. U „Odi radosti" Schiller slavi ideal bratstva među ljudima, viziju koju Beethoven dijeli. Godine 1972. Vijeće Europe prihvaća Beethovenovu „Odu radosti" za svoju himnu, a 1985. odlukom europskih čelnika postaje službena himna Europske unije. Bez teksta, na univerzalnom jeziku glazbe, ta himna izražava europske ideale slobode, mira i solidarnosti. Europska himna nije zamjena za nacionalne himne država članica, već se njome slave zajedničke vrijednosti.

- **Moto EU-a -** „Ujedinjena u raznolikosti", moto Europske unije, počinje se koristiti 2000. Taj moto označava ujedinjenje Europljana u EU – zajednicu za mir i blagostanje obogaćenu pritom različitošću svojih kultura, tradicija i jezika.

- **Dan Europe** - Ideje na kojima je osnovana Europska unija prvi je put predstavio francuski ministar vanjskih poslova Robert Schuman 9. svibnja 1950. Stoga 9. svibnja slavimo kao ključan datum za EU.

3. DEMOGRAFIJA I DEMOGRAFSKA STATISTIKA

3.1. Demografija

Pod demografijom najopćenitije razumijevamo društvenu znanost koja proučava stanovništvo s kvantitativnog i kvalitativnog aspekta.[14]

Sa stajališta kronološkog razvitka predmeta demografije i širine, te konzistentnosti sadržaja demografije kao znanstvene discipline, demografiju možemo definirati u užem i u širem smislu.

Uže poimanje predmeta demografije predstavlja tradicionalno poimanje, a demografiju poistovjećuje s demografskom statistikom. Predmet demografije u užem smislu obuhvaća brojnost i prostorni raspored stanovništva, prirodno kretanje (natalitet, mortalitet), mehaničko (migracijsko) kretanje, kao i starosno-spolnu strukturu stanovništva. Težište predmeta demografije u užem smislu leži na proučavanju prirodnog kretanja stanovništva.
Predmet demografije u širem smislu jest proučavanje brojnog stanja i prostornog razmještaja stanovništva, prirodnog i mehaničkog kretanja stanovništva i promjena u demografskim, socio-ekonomskim i ostalim strukturama stanovništva. Srž predmeta demografije koncipiranog u širem smislu čini tzv. demografski razvitak.

Pojam **demografski razvitak** je sinonim kompleksnog procesa razvitka stanovništva koji obuhvaća prirodno i mehaničko kretanje stanovništva i promjene u svim strukturama stanovništva, ali i u međusobnoj interakciji i sve to u sklopu djelovanja ekonomskih i socijalnih, bioloških, psiholoških i ostalih činilaca koji na direktan ili indirektan način uvjetuju ili pak usmjeravaju razvitak stanovništva u određenom pravcu.[15]

Na osnovu svega izloženog demografiju definiramo kao društvenu znanost koja istražuje zakone razvitka stanovništva u njihovoj povijesnoj i društveno-ekonomskoj uvjetovanosti. Osnovni cilj tako definirane demografije jest, prema tome, spoznaja osnovnih zakonitosti razvitka stanovništva, pronalaženje osnovnih tendencija toga razvitka u određenim ekonomskim i razvojnim uvjetima.

[14] Wertheimer-Baletić, A. (1999.): Stanovništvo i razvoj, MATE d.o.o., Zagreb.
[15] Čavrak, V. i skupina autora (2011.): Gospodarstvo Hrvatske, Politička kultura, Zagreb.

Demografija se u svojim istraživanjima u pogledu metodologije oslanja:[16]

1. na filozofiju, preko logike tj. preko uobičajenih logičkih metoda (apstrakcije, indukcije, dedukcije, analize i sinteze) i filozofije znanosti;
2. na povijest, u vezi s utvrđivanjem povijesnih činjenica razvitka populacije;
3. na statistiku i matematičke metode kao osnovni „tehnički“ instrumentarij prilagođen predmetu istraživanja demografije.

Zahvaljujući upravo razvitku demografske statistike, metodološki elementi demografije razvili su se prije nego li je definitivno određen predmet njezina proučavanja, bolje rečeno, širina predmeta proučavanja. Zbog toga se moderna demografija i razvila preko demografske statistike.

3.2. Demografska statistika

Pod pojmom demografske statistike podrazumijeva se grana statistike primijenjena na demografske pojave i procese. Stopa demografske statistike proučava specifičnosti prikupljanja podataka o stanovništvu (posebno metode popisivanja stanovništva, organizacijske statističke službe u vezi s provođenjem popisa, statistiku prirodnog kretanja stanovništva, statistiku migracija, provođenja anketa o ukupnom stanovništvu ili pojedinim skupinama stanovništva), obilježja stanovništva i klasifikacije, te problematiku obrade i prezentiranja podataka o stanovništvu.[17]

Dok statistika stanovništva registrira masovne pojave u stanovništvu koje se odnose na broj, razmještaj i strukturna obilježja stanovništva, vitalna statistika obuhvaća natalitet i mortalitet, kao i određene društvene pojave (sklapanje i razvod braka), a statistika migracija obuhvaća unutrašnje i vanjske migracije stanovništva jedne zemlje.

[16] Wertheimer-Baletić, A. (1999.): Stanovništvo i razvoj, MATE d.o.o., Zagreb.
[17] Wertheimer-Baletić, A. (1982): Demografija stanovništvo i ekonomski razvitak, Informator, Zagreb.

3.2.1. Stanovništvo kao varijabla demografske statistike

Pod pojmom **stanovništvo** podrazumijevamo specifičan skup osoba u kojem svaka osoba sudjeluje sa svojim posebnim obilježjima.[18] Na taj se način stanovništvo jednog teritorija po svojim obilježjima, karakteristikama, razlikuje od karakteristika pojedinih osoba koje čine njegov sastavni dio.

Značenje stanovništva u složenom procesu društvenog, ekonomskog i kulturnog života i razvitka jedne zemlje mnogostrano je i od izuzetne važnosti. Starosno-spolna struktura stanovništva, granska, profesionalna i druge strukture predstavljaju sferu u kojoj se isprepleće djelovanje niza činitelja (bioloških, socio-psiholoških, ekonomskih i drugih), u varijacijama različitog intenziteta, zavisno od stupnja razvoja proizvodnih snaga. Stanovništvo s niza svojih obilježja (struktura) proizvod je sveukupnih karakteristika sredine, u kojoj se razvija.

Ono nije fenomen koji se razvija izolirano od društveno–ekonomskih, kulturnih, tradicionalnih i drugih utjecaja sredine, po nekim svojim „autonomnim“ zakonima, već svaki posebni način proizvodnje ima svoje posebne zakone stanovništva čija je vrijednost povijesna. Stanovništvo prima te utjecaje, zavisno od njih mijenja svoja obilježja odnosno strukture, ali istodobno razvitak stanovništva određenih karakteristika povratno djeluje na te činitelje.

Činitelji koji djeluju na veličinu stanovništva i na stopu njegova kretanja (porasta ili smanjenja) u jednoj zemlji veoma su brojni i teško ih je klasificirati, to više što se njihovo djelovanje na veličinu i stopu rasta stanovništva često isprepleće pa je teško odrediti gdje određena grupa činitelja djeluje relativno samostalnije, a gdje uz sebe veže intenzivnije djelovanje drugih grupa činitelja. Međutim, zbog lakšeg uočavanja brojnih utjecaja koji djeluju u danom vremenu i prostoru na veličinu stanovništva i na njegovo kretanje, moguće je sve činitelje podijeliti u četiri grupe.
Na taj način dobivano sljedeće grupe činitelja:

a) demografski,
b) ekonomski,
c) politički
d) ostali.

[18] Čavrak, V. i skupina autora (2011.): Gospodarstvo Hrvatske, Politička kultura, Zagreb.

Svaka od tih grupa, ovisno o specifičnosti svog djelovanja na razvitak stanovništva može po svom vremenskom efektu djelovati dugoročno, kratkoročno i ciklički (periodično).

Kod definiranja pojma demografskog razvitka vidjeli smo da tzv. kretanje stanovništva čini njegov bitni sastavni dio. Sam naziv **kretanje stanovništva** ili, preciznije rečeno, ukupno kretanje stanovništva upozorava da se tu prije svega radi o promjenama u ukupnom broju stanovnika na određenom području i u određenom vremenu.

Ukupan broj stanovnika prva je i osnovna veličina koju dobivamo iz popisa stanovništva, a budući da je definirana u tzv. kritičnom trenutku popisa, trenutačan je statistički pokazatelj. U svakom popisu nužno je stoga definirati ukupan broj stanovnika, odnosno unaprijed odrediti koje ćemo stanovništvo smatrati stanovništvom određenog naselja ili regije.

Na dan 1. siječnja 2015.g ukupan broj stanovnika Europske unije iznosio je 508 504 320, a najnaseljenija država bila je Njemačka sa 81 197 537 stanovnika. Prema posljednjim poznatim podacima iz 2017. godine, broj stanovnika EU porastao je na 511 805 088, a najnaseljenija država i dalje je Njemačka, te broji 82 800 000 stanovnika. [19]

Povijest popisa pokazuje da su u popisima prevladavale, a i danas prevladavaju, uglavnom dvije osnovne definicije ukupnog stanovništva. Prva se temelji na koncepciji tzv. stalnog stanovništva, a druga na koncepciji tzv. prisutnog stanovništva.

Stalnim stanovništvom jednog područja smatraju se sve one osobe koje su na tom području imale mjesto stalnog boravka, bez obzira na to jesu li u trenutku popisa prisutne ili ne. To drugim riječima znači da svaka osoba mora biti popisana u mjestu svog stalnog boravka čak i u slučaju da se iz bilo kojeg razloga (putovanje, školovanje i slično) vrijeme popisa nalazi u drugom mjestu.

Prisutnim stanovništvom na jednom području smatraju se, kako samo ime kaže, sve one osobe koje su u kritičnom trenutku popisa bile prisutne na tom području, bez obzira na to imaju li tu stalan boravak ili ne.

[19] Eurostat, http://ec.europa.eu/eurostat/tgm/table.do?tab=table&plugin=1&language=en&pcode=tps00001 (22.8.2017.)

3.2.2. Izvori podataka o stanovništvu

Za demografska istraživanja od prvorazrednog su značenja raspoloživi izvori podataka o stanovništvu. Razlikujemo pet grupa tih izvora:[20]

1. popisi stanovništva – daju glavne izvore podataka o stanovništvu, teritorijalnom razmještaju i njegovim strukturama

2. knjige, tzv. demografske (vitalne) statistike – predstavljaju sustav tekuće statistike, tj. kontinuiranog praćenja podataka o vitalnim događajima (rođenje, smrt, vjenčanje) za ukupno stanovništvo na bazi podataka iz matičnih knjiga

3. posebne statističke publikacije o pojedinim relevantnim skupinama stanovništva – za potrebe istraživanja statističke službe prikupljaju podatke koji se odnose na specifične, za dotično područje relevantne segmente stanovništva i s tim u vezi objavljuju posebne publikacije (statistička priopćenja, dokumentaciju, biltene)

4. ankete o stanovništvu – vrijedan izvor podataka o pojedinim skupinama stanovništva ili kućanstva,o pojedinim oblicima potrošnje i sl.

5. razni upravni i drugi „registri“ pri pojedinim državnim i društvenim službama – u njima se vodi evidencija o pojedinim događajima u životu stanovništva

3.3. Temeljni demografski pokazatelji

3.3.1. Pokazatelji promjena u ukupnom broju stanovnika

Razlikujemo dvije skupine pokazatelja

a) Oni koji mjere promjene u apsolutnom iznosu
b) Oni koji mjere promjene u broju stanovnika relativno

[20] Wertheimer-Baletić, A. (1999.): Stanovništvo i razvoj, MATE d.o.o., Zagreb.

Najjednostavniji pokazatelj prve skupine jest tzv. **međupopisna promjena u broju stanovnika** (označavamo je sa D), koja izražava ukupni apsolutni iznos promjene nastale u broju stanovnika između dva popisa. Ako sa P_1 označimo broj stanovnika prvog popisa što smo ga uzeli u obzir,a sa P_2 broj stanovnika sljedećeg popisa, tada dobivamo da je:

$$D = P_2 - P_1 \text{ ili } D_1 = P_3 - P_2 \text{ , itd.}$$

Ovaj pokazatelj, međutim, nije pogodan za usporedbu ukupnog iznosa promjene broja stanovnika (porasta ili pada), kada su međupopisni intervali nejednaki. Stoga, da bismo mogli usporediti intenzitet promjena u broju stanovnika za nekoliko međupopisnih razdoblja, u apsolutnom iznosu treba izračunati **pokazatelj prosječne godišnje promjene broja stanovnika** ($\bar{R}$), tj. prosječni godišnji porast ili pad stanovništva na određenom području. Ako sa „t“ označimo broj godina (ili neki drugih jedinica vremena) između dva popisa dobijemo:

$$\bar{R} = \frac{P_2 - P_1}{t} = \frac{D}{t}$$

Da bismo dobili usporediv porast ili pad populacije između dva područja, važno je uzeti u obzir veličinu populacije iz koje je taj porast (ili pad) proizašao. Stoga treba izračunati relativni pokazatelj promjene nastale u broju stanovnika, odnosno tzv. **stopu ukupne promjene (porasta ili pada) broja stanovnika** između dva popisa koju označavamo sa „r“. Ona pokazuje veličinu promjene u broju stanovnika između dva popisa u odnosu na broj stanovnika određene populacije u prvom popisu. Može se izračunati na dva načina:

$$r = \frac{P_2 - P_1}{t} * 100 = \frac{D}{P_1} * 100$$

ili

$$r = 100 * \frac{P_2}{P_1} - 100$$

Relativni pokazatelj koji se također upotrebljava za mjerenje promjene u broju stanovnika između dva popisa, a temelji se na prosječnom broju stanovnika između dva popisa ($\bar{P}$) jest **stopa prosječne godišnje promjene** odnosno prosječnog godišnjeg porasta ili pada stanovništva za razdoblje između dva popisa. Označava se sa „r“, a izračunava se pomoću

prosječne godišnje promjene u apsolutnom iznosu ($\bar{R}$) i prosječnog broja stanovnika između dva popisa ($\bar{P}$) :

$$\bar{r} = \frac{\bar{R}}{\bar{P}} * 100 \,, \quad \bar{P} = \frac{P_1 + P_2}{2}$$

3.3.2. Ukupno kretanje stanovništva

Natalitet (N) i imigracije (I) čine, naime, pozitivne komponente ukupnog kretanja stanovništva ili „aktivu“ demografske bilance, jer zajednički djeluju u pravcu porasta populacije, dok mortalitet (M) i emigracije (E) čine negativne komponente ukupnog kretanja stanovništva ili „pasivu“ demografske bilance, jer zajednički djeluju u pravcu smanjenja broja stanovnika.

Tijekom 2015. godine u Europskoj uniji rođeno je gotovo 5,1 milijuna beba, dok je više od 5,2 milijuna osoba umrlo, što znači da je u Europskoj uniji prvi put u povijesti zabilježeno negativno prirodno kretanje stanovništva. Ostale pozitivne promjene uglavnom su rezultat migracija.[21]

3.3.3. Komponente prirodnog kretanja stanovništva

Osnovne komponente prirodnog kretanja stanovništva su natalitet (rodnost) i mortalitet (smrtnost) stanovništva, a njihova je rezultanta u pravilu prirodni prirast (višak rođenih nad brojem umrlih). Ako se pojavi obrnuta situacija, tj. višak umrlih nad brojem rođenih, tada govorimo o prirodnom padu stanovništva ili o negativnom prirastu. Nulti prirast ili prirodna stagnacija stanovništva jest situacija koja nastaje kada se broj rođenih u određenom razdoblju izjednačava s brojem umrlih.

Fertilitet (natalitet) jest pozitivna komponenta prirodnog kretanja koja, uz ostale iste uvjete, djeluje na porast stanovništva jednog područja. Pojam nataliteta (rodnosti) stanovništva pojavljuje se u demografskoj literaturi i pod nazivom fertilitet (plodnost). U biti se, gledano u širem smislu, pojmovi natalitet i fertilitet ne razlikuju, jer se odnose na istu pojavu, tj. na broj rođenja u određenoj populaciji u određenom razdoblju. Dakle, gledano u širem smislu, pod pojmovima natalitet odnosno fertilitet razumijevamo kvantitativne pojave vezane neposredno

[21] Europe Direct Čakovec, https://edic-cakovec.eu/stanovnistvo-eu-a-u-2016-broji-vise-od-510-milijuna-stanovnika/ (22.08.2017.)

za rađanje djece u cjelokupnoj populaciji nekog područja ili u jednom njezinom dijelu. Kada pojmove natalitet i fertilitet uzmemo u njihovom užem značenju, tada pod pojmom natalitet označavamo broj živorođenih u odnosu na ukupno stanovništvo, a pod pojmom fertilitet označavamo broj živorođenih u odnosu na žensko stanovništvo u fertilnoj dobi (15-49 godina). Nadalje u demografskoj teoriji razlikujemo pojmove fertilitet i fekonditet.

Tako se pod pojmom **fekonditeta** razumijeva potencijalna fiziološka plodnost ili fiziološka sposobnost sudjelovanja u reprodukciji stanovništva, a pod fertilitetom ostvarenje te fiziološke sposobnosti ili efektivna plodnost izražena kroz stvarni broj potomaka.

Najjednostavniji ali istodobno i najgrublji pokazatelj frekvencije rođenja u jednom stanovništvo jest tzv. **stopa nataliteta** koja se zbog svojih svojstava naziva opća (ili gruba) stopa nataliteta, a može se odnositi na ukupan broj rođenih u jednoj godini (živorođeni plus mrtvorođeni) koji označavamo sa N_u pa tada govorimo o stopi ukupnog nataliteta (n_u), no mnogo se češće upotrebljava opća stopa nataliteta koja se odnosi samo na ukupan broj živorođenih u jednoj godini (N), a naziva se opća stopa (efektivnog) nataliteta (n) te se izračunava:

$$n = \frac{N}{P} \cdot 1000$$

gdje nazivnik (P) označava stanovništvo uzeto sredinom godine.

Da bi se izbjegli nedostatci opće stope nataliteta izračunavaju se preciznije mjere fertiliteta. Prva među njima, koja donekle uklanja osnovni nedostatak opće stope nataliteta u pogledu sadržaja nazivnika, jest **stopa ukupnog fertiliteta** (f_u) koja se izračunava također kao godišnja stopa stavljanjem u odnos broja živorođenih (N) i ukupnog (muškog i ženskog) stanovništva u fertilnom razdoblju života.

$$f_u = \frac{N}{P_{f\,(15–49)} + P_{m(15–64)}} \cdot 1000$$

Najčešće upotrebljavana i najpreciznija mjera fertiliteta stanovništva jest **opća stopa fertiliteta ili opća stopa ženskog fertiliteta,** koja daje realniju sliku o visini fertiliteta. Ona u nazivniku sadrži ukupno žensko stanovništvo u fertilnom razdoblju života, dakle, onaj kontigent stanovništva koji direktno sudjeluje u reprodukciji stanovništva.

$$f = \frac{N}{P_{f(15-49)}} \cdot 1000$$

Stopa fertiliteta se odnosi na broj živorođene djece koja otpada na 1000 žena.

U demografskoj statistici najboljim pokazateljem fertiliteta smatra se tzv. **ukupna (totalna) stopa fertiliteta-TRF.**
Ona označava prosječan broj živorođene djece koju bi rodila žena tokom svog fertilnog razdoblja uz pretpostavke da djeluju posebne stope fertiliteta dobi i uz izostanak utjecaja smrtnosti.
Zbroj svih specifičnih stopa fertiliteta od 15 do 49 godina, prema jednogodišnjem dobu:

$$F_X = \frac{\sum_{15}^{49} f_X}{1000}$$

Mortalitet je negativna komponenta prirodnog i ukupnog kretanja stanovništva koje djeluje na smanjivanje ukupnog broja stanovnika. Budući da je proces starenja i umiranja biološki kontinuiran, on sam po sebi nameće potrebu kvantitativne i kvalitativne zamjene umrlih novim naraštajima. Pri tome se ne radi samo o potrebi zamjene broja umrlih po kvantiteti, već i po kvaliteti. Razina mortaliteta u jednoj zemlji izraz je kompleksnog djelovanja bioloških, ekonomskih i socijalnih činitelja.

Pod pojmom mortalitet (smrtnost) razumijevamo učestalost umiranja u jednoj populaciji, pri čemu se pojam mortalitet često poistovjećuje s općom stopom mortaliteta. Opću (grubu) stopu mortaliteta (m) izračunavamo kao odnos broja umrlih u toku godine (M) i broja stanovnika sredinom godine (P):

$$\mathrm{m} = \frac{M}{P} * 1000$$

Najčešće korišteni indikator za analizu mortaliteta jest očekivano trajanje života ili očekivana dob, koji predstavlja broj godina koje pojedinac u određenoj dobi može očekivati da će doživjeti uz trenutne razine smrtnosti.

Pojam **migracije** stanovništva (mehaničko kretanje) označava prvenstveno prostornu pokretljivost, odnosno prostornu mobilnost stanovništva. Prostorna jedinica proučavanja migracijskih kretanja je država (ako se radi o vanjskoj migraciji) ili manja administrativno-teritorijalna jedinica (naselje, općina) ako se radi o unutrašnjoj migraciji.
Jedinica promatranja stanovništva koje migrira (migrantskog stanovništva) je migrant, po kojem se, u užem smislu, smatra osoba koja definitivno mijenja mjesto stalnog boravka i to kako u unutrašnjoj tako i u vanjskoj migraciji.

Migracija se obično definira kao trajnija promjena mjesta stalnog boravka. Osnovne komponente migracije stanovništva su prema tome imigracija (useljavanje, doseljavanje) i emigracija (iseljavanje, odseljavanje).

Razlika između imigracije (I) u određeno područje i emigracije (E) iz dotičnog područja u određenom razdoblju naziva se **migracijski saldo, neto migracija ili migracijska bilanca** (I-E). Ako je broj imigranata veći od broja emigranata (I > E) tada imamo pozitivni migracijski saldo, pozitivnu neto migraciju ili mehanički prirast. Obrnuto, kada je broj emigranata iz područja veći od broja imigranata (E > I) tada imamo negativan migracijski saldo, negativnu neto migraciju ili mehanički pad. Ako se broj imigranata poklapa s brojem emigranata (I = E) tada govorimo o nultom prirastu ili o ravnotežnoj migraciji.

Pod pojmom **bruto migracije** podrazumijevamo ukupan broj migranata između dvije administrativno-teritorijalne jedinice, tj. zbroj emigranata i imigranata između dvije administrativno-teritorijalne jedinice u danom razdoblju (I + E). Prema tome, bruto migracija predstavlja ukupnu prostornu pokretljivost stanovništva za dano područje.

Imajući u vidu navedene opće pojmove o migracijama, imamo sljedeće osnovne agregatne pokazatelje migracija (opće stope), koji pokazuju učestalost migracija stanovništva unutar dane administrativno-teritorijalne jedinice:

1. Opća stopa bruto-migracija (y_b) označava kvocijent apsolutnog iznosa bruto-migracija (Y_b) u danoj godini i broja stanovnika sredinom te godine (P) :

$$y_b = \frac{Y_b}{P} * 1000 = \frac{I-E}{P}$$

Y_b = I + E = ukupna ili bruto-migracija

I = ukupan broj migranata

E = ukupan broj emigranata

2. Opća stopa neto-migracije ili migracijskog salda (y_n) označava kvocijent apsolutnog iznosa migracijskog salda (Y_n) u danoj godini i broja stanovnika sredinom te godine (P):

$$y_n = \frac{Y_n}{P} * 1000 = \frac{I-E}{P}$$

$$y_n = I - E$$

I – E = migracijski saldo ili neto migracijski saldo

Valja napomenuti da se navedena stopa migracijskog salda u praksi najčešće upotrebljava kao agregatni pokazatelj učestalosti migracija i da se pod općom, stopom migracija (ili samo pod pojmom „stopa migracija“) misli najčešće upravo na ovaj pokazatelj.

3. Opća stopa imigracije ili useljavanja (i) predstavlja kvocijent imigracije (I) na dano područje i broj stanovnika sredinom te godine (P) :

$$i = \frac{I}{P} * 1000$$

4. Opća stopa emigracije ili iseljavanja (e) predstavlja kvocijent emigracije (E) iz određenog područja i ukupnog broja stanovnika sredinom te godine (P):

$$e = \frac{E}{P} * 1000$$

4. METODE KLASIFICIRANJA

4.1. Multivarijacijska Cluster analiza

Multivarijacijska analiza (MVA) temelji se na principima multivarijacijske statistike, koja uključuje promatranja i analize dvije ili više statističkih varijabli istovremeno. Ove tehnike u praksi se koriste u smislu više dimenzijskih analiza u kojima se uvažavaju utjecaji i efekti svih relevantnih varijabli.[22]

Multivarijacijska analiza ocjenjuje međuovisnosti varijabli i vrši njihovo grupiranje u skladu s njihovom sličnošću (faktorska analiza) i/ili vrši grupiranje slučajeva (podataka) opet u skladu s njihovom sličnošću tj. povezanosti (Cluster analiza).

Multivarijacijska analiza može se provoditi u smislu istraživanja i potvrđivanja. Istraživačka analiza provodi se da bi se otkrile glavne zajedničke karakteristike većeg broja varijabli. Pri istraživanju postavlja se a priori pretpostavka o potencijalnoj povezanosti promatranih faktora. Kod analize gdje se vrši potvrđivanje, utvrđuje se jesu li odgovarajući faktori i varijable koje utječu na njih zaista u skladu s načelima unaprijed utvrđene ekonomske teorije.

Cluster analiza je vrsta multivarijacijske statističke analize koja spada u metode klasificiranja. Temelji se na matematički formuliranim mjerama sličnosti i obuhvaća različite postupke, algoritme i metode grupiranja podataka. Osnovni problem s kojim se istraživači susreću u praksi je na koji način najprije organizirati skupljene podatke, a zatim koji je algoritam najbolje upotrijebiti.

Cluster analiza spada u istraživačke analize čiji je osnovni cilj sortirati različite podatke u grupe na način da se maksimizira stupanj sličnosti unutar grupe uz uvjet da je sličnost s drugim grupama minimalna.

Metode grupiranja ili klasificiranja u osnovi se mogu podijeliti na hijerarhijske i nehijerarhijske.

[22] Pivac, S. (2010): Statističke metode, Ekonomski fakultet u Splitu, Split.

4.1.1. Hijerarhijske metode

Među hijerarhijske metode klasificiranja ubrajamo:[23]

- **Metoda udruživanja ili aglomerativna metoda** je metoda gdje je u početku svaka jedinica poseban klaster, a zatim se jedinice grupiraju u sve manji broj grupa, dok se sve ne svrstaju u jednu veliku grupu
- **Metoda dijeljenja** po kojoj se velika grupa, koja u početku sadrži sve jedinice, dijeli na sve veći broj grupa, sve dok svaka jedinica ne postane zasebna grupa.

Ove metode u svakom koraku daju različito rješenje s obzirom na broj i sastav klastera. U praktičnim istraživanjima se postavlja pitanje o odabiru optimalnog, tj. „pravog" rješenja. Sve to ovisi o vrsti istraživanja uz uvažavanje ekonomske teorije i tzv. efekta „parasimonije" i mogućnosti interpretacije.

Pri provođenju hijerarhijskih grupiranja u stvari se traži najmanja od udaljenosti:

- Udaljenost između dva najsličnija klastera
- Udaljenost između postojećih klastera i negrupiranih jeidnica
- Udaljenost između dvije najsličnije negrupirane jedinice

Sljedeći korak pri provođenju metode ovisi o tome koja je od ovih udaljenosti najmanja. Različite hijerarhijske metode na različit način određuju udaljenost između klastera tj. između klastera i negrupiranih jedinica, npr:[24]

- **metoda međusobnog povezivanja** (Between-groups linkage), koja se temelji na maksimiziranju udaljenosti između svakog para jedinica iz dva različita klastera. Udaljenost između dva klastera ovdje se računa kao prosjek udaljenosti svih kombinacija parova jedinica iz ta dva klastera.

- **metoda povezivanja unutar grupa** (Within-groups linkage), koja se temelji na minimalnoj udaljenosti svih jedinica unutar klastera. I ovdje je udaljenost jedinica

[23] Ibid.
[24] Ibid.

prosjek udaljenosti svih kombinacija parova jedinica iz tog novonastalog klastera.

- **metoda najbližeg susjeda** (Nearest neighbor) ili jednostrukog povezivanja (Single linkage) pretpostavlja da je udaljenost među dva klastera jednaka udaljenosti između dvije najbliže jedinice iz ta dva klastera.

- **metoda najdaljeg susjeda** (Furthest neighbor) ili potpunog povezivanja (Complete linkage) pretpostavlja da je udaljenost među dva klastera jednaka udaljenosti između dvije najdalje jedinice iz ta dva klastera.

- tzv. **centroidna metoda** (Centroid clustering) ili ponderirana centroidna metoda (Weighted pair-group centroid) pretpostavlja da je udaljenost među dva klastera jednaka udaljenosti između aritmetičkih sredina svih jedinica iz ta dva klastera.

- **metoda medijana** (Median clustering) ili neponderirana centroidna metoda (Unweighted pair-group centroid) je slična prethodnoj metodi, samo bez ponderiranja.

- **Ward-ova metoda** (Ward's method) temelji se na najmanjoj Euklidskoj udaljenosti svake jedinice od aritmetičke sredine (što u stvari predstavlja analizu varijance) za cijeli klaster kojem ta jedinica pripada.

Grafički prikaz grupiranja je tzv. **grafikon matričnog stabla ili dendrogram** koji vizuelno u dvodimenzionalnom prostoru pokazuje hijerarhiju unutar konačnog klastera, gdje je napravljena podjela kroz binarno stablo. Dendrogram prikazuje i stvarne udaljenosti na skali od 0 do 25.

Cluster postupak (aglomerativna) se može opisati na sljedeći način:

- svaka jedinica na početku je zaseban klaster
- ocjenjuju se sve odgovarajuće udaljenosti između jedinica i/ili klastera
- formira se matrica udaljenosti koristeći dobivene udaljenosti

- traži se najmanja udaljenost
- par jedinica ili klastera s najmanjom udaljenosti se odvaja iz matrice
- nakon toga ocjenjuju se sve udaljenosti između tog „novog“ klastera sa svim preostalim jedinicama i/ili klasterima i formira se nova matrica udaljenosti
- cijeli postupak se ponavlja dok u matrici udaljenosti ne ostane samo jedan element.

Najčešće korištena mjera udaljenosti između numeričkih podataka je Euklidska udaljenost i Euklidska kvadratna udaljenost.

4.1.2. Nehijerarhijske metode

Od **nehijerarhijskih metoda** u praksi je najviše u upotrebi **k-means metoda** tj. metoda k-prosjeka. Prednost i/ili nedostatak ove metode, što naravno ovisi i o vrsti istraživanja, je što se unaprijed treba odabrati broj klastera. Jedinice se tada pridružuju klasteru kojem su najbliži, tj. s kojim imaju najmanju Euklidsku udaljenost. Ako je potrebno, neke jedinice se premještaju iz klastera u klaster sve dok se ne postigne stabilnost sustava. Naravno i ovdje vrijedi kriterij minimalnih udaljenosti jedinica unutar klastera i maksimalnih udaljenosti između klastera.

Pri određivanju broja klastera može se poći od teorijskih postavki (ekonomskih) vezanih za istraživanje koje se provodi. **ANOVA testiranje** odnosi se na svaku promatranu varijablu i upućuje na zaključak je li se sredine između predloženih klastera signifikantno razlikuju. Ako empirijske p-vrijednosti ne premašuju graničnu signifikantnost od 5% može se zaključiti da se sredine između predloženih klastera značajno razlikuju. U suprotnom je potrebno promijeniti predloženi broj klastera i/ili promatrane varijable.

Ako se neka jedinica nikako ne može klasterirati ni u višim fazama klasteriranja, ona se smatra netipičnom vrijednošću (outlier). Takva jedinica se zove Runt ili Entropy grupa.

Cluster analiza **ne pretpostavlja nikakvu statističku značajnost**, pa je u praksi uobičajeno koristiti i dodatne odgovarajuće statističke testove da bi se potvrdili zaključci na znanstvenoj razini.

Cluster analizom uvijek se postiže neka klasifikacija. Rješenja nisu uvijek jedinstvena jer zavise o varijablama koje su uključene u analizu, ali i o načinu kako je kluster definiran. Međutim potrebno je napomenuti da je cluster metoda grupiranja nepristrana i transparentna.

Uvažava konkretne matematičke izračune i za rezultat ima nepristrano grupiranje promatranih jedinica, naravno ako su podaci koji se koriste u analizi također nepristrani.

4.1.3. K-means metoda

Osnovna ideja algoritma k-means je određivanje predstavnika k skupina, i pridruživanje svake točke skupini s najbližim predstavnikom tako da zbroj kvadrata udaljenosti točaka od predstavnika skupina kojima pripadaju bude minimalan. Drugim riječima, algoritam k-means generira skupine s minimalnom totalnom varijancom (najkompaktnije moguće skupine).

Nedostatak algoritma je u tome sto se na izlazu dobiva samo stabilno, a ne nužno i optimalno rješenje. Odnosno, rješenje bitno ovisi o početnoj k-torci predstavnika skupina. Drugi nedostatak algoritma k-means je u tome što može prepoznati samo skupine odvojive hiperravninama.

Koraci koji se javljaju kod K-means metode su:[25]

1. Inicijalizacija - Slučajno odabiremo ***k*** središta grupa kao i ***k*** slučajno odabranih točaka unutar hipervolumena koji sadrži podatke tj. primjere.[26]

2. Pridruživanje - Pridružujemo svaki primjer najbližem (npr. prema kvadratnoj pogrešci) ranije određenom središtu grupe

3. Prepravljanje - Izračunaj nova središta grupa

4. Ako kriterij konvergencije nije postignut, vrati se na točku (2). Tipični kriteriji konvergencije su: minimum ponovnog pridruživanja primjera novom središtu grupe ili minimalno smanjenje kvadrata pogreške.

Algoritam k-means je iterativni algoritam koji ponavlja dva koraka dok se ne zadovolji neki kriterij konvergencije. U drugom koraku **„pridruživanje“** svaka točka pridružuje se najbližem predstavniku (određuje se particija). U drugom koraku **„prepravljanje”** skup predstavnika se prepravlja - za nove predstavnike se uzimaju središta skupina definiranih u koraku „pridruživanje”. Algoritam se zaustavlja kada se vrijednost ciljne funkcije prestane smanjivati.

[25] Moore, A. (2001): K-means and Hierarchical Clustering.
[26] ***k*** predstavlja broj grupa (klastera)

Prilikom izvršavanja algoritma k-means može se dogoditi da neki predstavnik ostane bez pridruženih mu točaka (ako su sve točke bliže ostalim predstavnicima). Sama heuristika k-sredina ne govori o tome kako postupiti u situaciji kada skupina u nekom koraku ostane prazna. Uobičajene strategije u praksi su:[27]

- premještanje predstavnika ispražnjene skupine slučajnim izborom ili proizvoljno
- uzimanje točke koja je najudaljenija od svog predstavnika za novu jednočlanu skupinu
- zadržavanje predstavnika (ostavlja se mogućnost da skupina ponovo primi točke)
- brisanje predstavnika skupine koja je ostala prazna.

[27] Mirošević, I. (2017): k-means Algorithm, KoG, 20(20), 91-98.

5. MULTIVARIJACIJSKA ANALIZA ZEMALJA EU-28 PREMA NJIHOVIM DEMOGRAFSKIM ZNAČAJKAMA U 2015. GODINI

5.1. Kriteriji klasificiranja

Prilikom provođenja Cluster analize važno je odrediti uzorak koji će biti podvrgnut Cluster analizi kao i skup relevantnih varijabli koje će reprezentirati obilježja objekta.

U ovom radu uzorak se sastoji od 28 zemalja članica Europske unije - Austrija, Belgija, Bugarska, Cipar, Češka, Danska, Estonija, Finska, Francuska, Grčka, Hrvatska, Irska, Italija, Litva, Latvija, Luksemburg, Mađarska, Malta, Nizozemska, Njemačka, Poljska, Portugal, Rumunjska, Slovačka, Slovenija, Španjolska,Švedska i Ujedinjeno Kraljevstvo.

Kao i kod većine multivarijacijskih metoda jedna od najvažnijih odluka je izbor varijabli (mjera, osobina) koje najbolje reprezentiraju koncept sličnosti koji istražujemo na nekom skupu objekata. U ovom radu odabrane su sljedeće varijable:

- Broj rođenih – ukupan broj živorođene djece
- Broj umrlih – ukupan broj umrlih
- Imigracije – ukupan broj imigranata (useljenika) s obzirom na zemlju rođenja
- BDP per capita - BDP po glavi stanovnika u standardima kupovne moći (PPS) u odnosu na prosjek EU-28, tj. BDP prilagođen veličini gospodarstva u odnosu na broj stanovnika i razlike u cijenama među državama.[28] Prosjek EU-28 postavljen je na 100.
- Fertilitet – ukupna stopa fertiliteta dobivena kao omjer broja živorođenih i ukupnog muškog i ženskog stanovništva u fertilnom razdoblju
- Godine zavisnosti mladog stanovništva – predstavlja omjer mladog stanovništva (ispod 15 godina) koje je ekonomski neaktivno, tj. nezaposleno u odnosu na radno stanovništvo.[29]
- Godine zavisnosti starog stanovništva - predstavlja omjer starog stanovništva (65 godina i više) koje je ekonomski neaktivno, tj. nezaposleno u odnosu na radno stanovništvo. [30]

[28] Eurostat, http://ec.europa.eu/eurostat/statistics-explained/index.php/Glossary:Purchasing_power_standard_(PPS) (26.07.2017.)
[29] Eurostat, http://ec.europa.eu/eurostat/statistics-explained/index.php/Glossary:Young-age-dependency_ratio (26.07.2017.)
[30] Eurostat, http://ec.europa.eu/eurostat/statistics-explained/index.php/Glossary:Old-age-dependency_ratio (26.07.2017.)

- Tražitelji azila – ukupan broj osoba koje su zatražile azil u zemljama EU-28, a dolaze izvan zemalja EU-28
- Stopa zaposlenosti - omjer broja zaposlenih i ukupno raspoloživih resursa radne snage izražen kao postotak. Obuhvaća sve osobe u dobi od 20 do 64 godine.

Važno je napomenuti da se podaci odabranih varijabli odnose na svaku pojedinu zemlju EU-28 u 2015. godini.

5.2. Metodologija klasificiranja

Prilikom provođenja Cluster analize korištene su hijerarhijske i nehijerarhijske metode.

Zbog načela usporedne analize klasificiranja ustrajalo se na izboru „Between Groups“ za „Average Linkage“ kao i na Euklidskoj distanci pri izboru vrte udaljenosti.

Analiza osjetljivosti rezultata na promjenu broja klastera kao značajnog inicijalnog dijela ulaznih podataka izvršena je u načelu empirijski, varirajući klastere od 15 do 5!

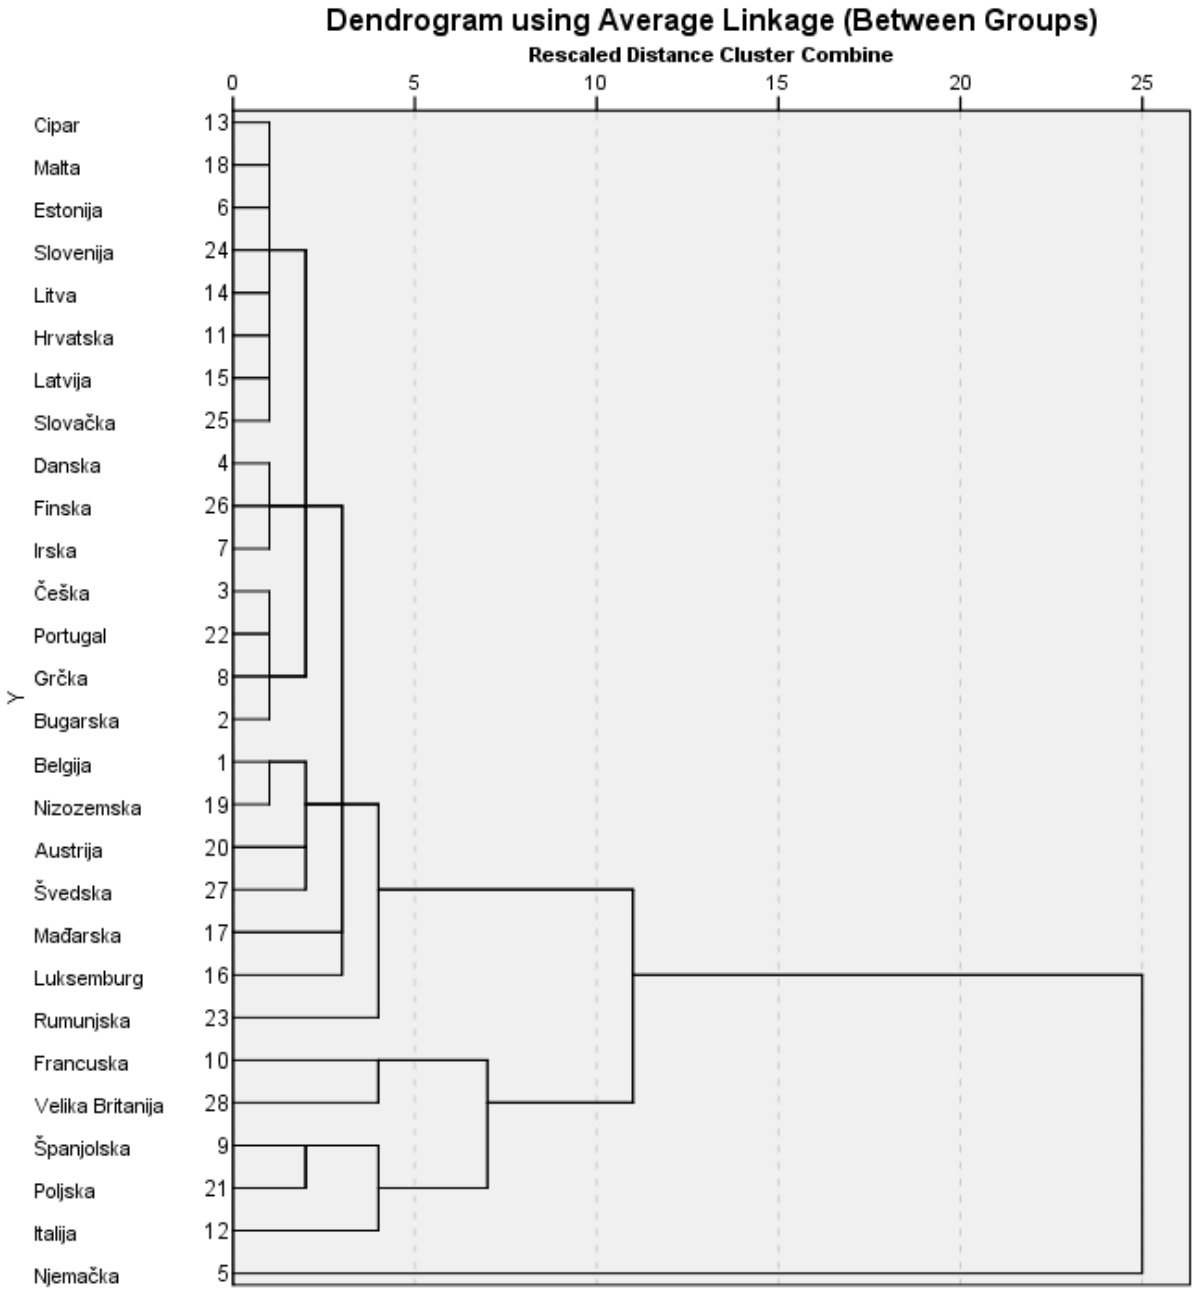
Budući da je izvršeno 100-tinjak procesa klasificiranja EU-28 prema njihovim raspoloživim demografskim pokazateljima na ovom mjestu nemoguće je prikazati sve dobivene rezultate. Stoga će se prikazati za svaki broj klastera po jedan output koji se pojavio za taj određeni broj klastera najmanje 60% puta. To znači da je npr. klasificiranje EU-28 u 15 klastera napravljeno 10-ak puta varirajući broj i izbor kriterija klasificiranja.

5.2.1. Klasificiranje u 15 klastera

Ovdje se prikazuju rezultati klasificiranja u 15 klastera koji su se pojavili 7 puta (dakle, više od 60% puta od ukupnog broja klasificiranja u 15 klastera).

U prikazanom slučaju korištena je hijerarhijska metoda udruživanja ili aglomerativna metoda, a izvršeno je grupiranje 28 zemalja Europske unije prema 9 odgovarajućih demografskih pokazatelja za 2015. godinu.

Nakon provedene multivarijacijske cluster analize jedan od dobivenih outputa je dendogram[31] klasifikacije država.



Slika 2. Klasifikacija zemalja EU-28 u 15 klastera prema demografskim značajkama u 2015. godini pomoću dendograma

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

[31] Algoritmi za hijerarhijsko klasteriranje konstruiraju hijerarhiju unutar klastera prikazanu kroz binarno stablo koje se naziva dendogram.

Iz dendrograma vidljivo je da su Danska, Finska i Irska klasificirane zajedno u jednu grupu. Hrvatska je klasificirana kao slična s Estonijom, Ciprom, Latvijom, Litvom, Maltom, Slovenijom i Slovačkom, a Bugarska i Češka tvore grupu zajedno sa Grčkom i Portugalom. Najmanju grupu tvore Nizozemska i Belgija, dok se ostale zemlje članice Europske unije, prema demografskim karakteristikama, klasificiraju kao zasebne.

Tablica 1. Klasifikacija zemalja EU-28 prema demografskim značajkama u 2015. godini u 2 do 15 klastera pomoću hijerarhijske metode

Cluster Membership														
Case	15 Clust-ers	14 Clust-ers	13 Clust-ers	12 Clust-ers	11 Clust-ers	10 Clust-ers	9 Clust-ers	8 Clust-ers	7 Clust-ers	6 Clust-ers	5 Clust-ers	4 Clust-ers	3 Clust-ers	2 Clust-ers
1:Belgija	1	1	1	1	1	1	1	1	1	1	1	1	1	1
2:Bugarska	2	2	2	2	2	2	2	1	1	1	1	1	1	1
3:Češka	2	2	2	2	2	2	2	1	1	1	1	1	1	1
4:Danska	3	3	3	3	2	2	2	1	1	1	1	1	1	1
5:Njemačka	4	4	4	4	3	3	3	2	2	2	2	2	2	2
6:Estonija	5	5	3	3	2	2	2	1	1	1	1	1	1	1
7:Irska	3	3	3	3	2	2	2	1	1	1	1	1	1	1
8:Grčka	2	2	2	2	2	2	2	1	1	1	1	1	1	1
9:Španjolska	6	6	5	5	4	4	4	3	3	3	3	3	3	1
10:Francuska	7	7	6	6	5	5	5	4	4	4	4	4	3	1
11:Hrvatska	5	5	3	3	2	2	2	1	1	1	1	1	1	1
12:Italija	8	8	7	7	6	6	6	5	5	5	5	3	3	1
13:Cipar	5	5	3	3	2	2	2	1	1	1	1	1	1	1
14:Litva	5	5	3	3	2	2	2	1	1	1	1	1	1	1
15:Latvija	5	5	3	3	2	2	2	1	1	1	1	1	1	1
16:Luksemburg	9	9	8	8	7	7	7	6	1	1	1	1	1	1
17:Mađarska	10	10	9	9	8	8	1	1	1	1	1	1	1	1
18:Malta	5	5	3	3	2	2	2	1	1	1	1	1	1	1
19:Nizozemska	1	1	1	1	1	1	1	1	1	1	1	1	1	1
20:Austrija	11	11	10	1	1	1	1	1	1	1	1	1	1	1
21:Poljska	12	12	11	10	9	4	4	3	3	3	3	3	3	1
22:Portugal	2	2	2	2	2	2	2	1	1	1	1	1	1	1
23:Rumunjska	13	13	12	11	10	9	8	7	6	1	1	1	1	1
24:Slovenija	5	5	3	3	2	2	2	1	1	1	1	1	1	1
25:Slovačka	5	5	3	3	2	2	2	1	1	1	1	1	1	1
26:Finska	3	3	3	3	2	2	2	1	1	1	1	1	1	1
27:Švedska	14	11	10	1	1	1	1	1	1	1	1	1	1	1
28:Velika Britanija	15	14	13	12	11	10	9	8	7	6	4	4	3	1

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

Tablice 1. pokazuje da su Belgija i Nizozemska po demografskim karakteristikama jako slične jer se drže čvrsto zajedno, bez obzira na promjenu broja klastera, dok promjena broja klastera utječe na grupiranje svih ostalih zemalja članica EU.

5.2.2. Klasificiranje u 14 klastera

U prikazanom slučaju korištena je nehijerarhijska metoda k-prosjeka. Rezultati pokazuju klasificiranje u 14 klastera koji su se pojavili 8 puta (dakle, više od 60% puta od ukupnog broja klasificiranja u 14 klastera). Izvršeno je grupiranje 28 zemalja Europske unije prema 9 odgovarajućih demografskih pokazatelja za 2015. godinu.

Tablica 2. prikazuje klasifikaciju zemalja EU-28 na osnovu odabranih demografskih pokazatelja pomoću klaster metode k-prosjeka. Na temelju prikazanog vidljivo je da Bugarska, Češka, Grčka i Portugal i dalje tvore jednu grupu, a Belgiji i Nizozemskoj se pridružila i Austrija. Hrvatska se i dalje nalazi u grupi sa Estonijom, Ciprom, Litvom, Latvijom, Maltom, Slovenijom, Slovačkom, a u istu grupu svrstala se i Finska. Danska i Irska tvore jednu grupu, dok se ostale zemlje članice Europske unije klasificiraju kao zasebne.

Tablica 2. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 14 klastera pomoću metode k-prosjeka

Cluster Membership		
Case Number	Država	Cluster
1	Belgija	1
2	Bugarska	11
3	Češka	11
4	Danska	7
5	Njemačka	5
6	Estonija	13
7	Irska	7
8	Grčka	11
9	Španjolska	9
10	Francuska	10
11	Hrvatska	13
12	Italija	12
13	Cipar	13
14	Litva	13
15	Latvija	13
16	Luksemburg	6
17	Mađarska	14
18	Malta	13
19	Nizozemska	1
20	Austrija	1
21	Poljska	3
22	Portugal	11
23	Rumunjska	8
24	Slovenija	13
25	Slovačka	13
26	Finska	13
27	Švedska	4
28	Velika Britanija	2

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

Tablica 3. Prikazuje ANOVA testiranje za klaster metodu k-prosjeka. ANOVA testiranje odnosi se na svaku od promatranih varijabli te upućuje na zaključak je li se sredine između predloženih klastera značajno razlikuju.

Iz tablice 3. je vidljivo da empirijske p-vrijednosti kod varijabli *Godine zavisnosti starog stanovništva* i *Stopa zaposlenosti* značajno premašuju graničnu signifikantnost od 5%, te se može zaključiti da te dvije varijable ne pridonose značajnoj razlici između klastera. Dok

empirijske vrijednosti kod ostatka varijabli ne premašuju graničnu signifikantnost od 5%, te se može zaključiti da se sredine između predloženih klastera značajno razlikuju.

Tablica 3. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 14 klastera pomoću metode k-prosjeka

ANOVA			
	df	F	Sig.
Broj rođenih (000)	14	222,257	0,000
Broj umrlih (000)	14	287,247	0,000
Imigracije (000)	14	1685,84	0,000
BDP per capita (%)	14	13,496	0,000
Fertilitet	14	2,845	0,031
Godine zavisnosti mladog stanovništva	14	3,288	0,017
Godine zavisnosti starog stanovništva	14	1,283	0,324
Tražitelji azila (000)	14	89,168	0,000
Stopa zaposlenosti	14	1,127	0,412

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

5.2.3. Klasificiranje u 13 klastera

Sada se prikazuju rezultati klasificiranja u 13 klastera koji su se pojavili 7 puta (dakle, više od 60% puta od ukupnog broja klasificiranja u 13 klastera).

I u ovom slučaju korištena je nehijerarhijska metoda k-prosjeka. Izvršeno je grupiranje 28 zemalja Europske unije prema 9 odgovarajućih demografskih pokazatelja za 2015. godinu.

Iz Tablice 4. je vidljivo kako je smanjenje broja klastera sa 14 na 13 jedino utjecalo na promjenu u grupi Belgije,Nizozemske i Austrije jer im se sada pridružila i Švedska. Grupa Hrvatske, Estonije, Cipra, Litve, Latvije, Malte, Slovenije, Slovačke, Finske ostaje ne promijenjena, kao i grupa Danske i Irske. Jedini klaster kojem do sada nije smetalo ni jedno smanjenje je onaj Bugarske, Češke, Grčke i Portugala.

Tablica 4. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 13 klastera pomoću metode k-prosjeka

Cluster Membership		
Case Number	Država	Cluster
1	Belgija	4
2	Bugarska	2
3	Češka	2
4	Danska	7
5	Njemačka	5
6	Estonija	6
7	Irska	7
8	Grčka	2
9	Španjolska	9
10	Francuska	10
11	Hrvatska	6
12	Italija	12
13	Cipar	6
14	Litva	6
15	Latvija	6
16	Luksemburg	13
17	Mađarska	11
18	Malta	6
19	Nizozemska	4
20	Austrija	4
21	Poljska	3
22	Portugal	2
23	Rumunjska	8
24	Slovenija	6
25	Slovačka	6
26	Finska	6
27	Švedska	4
28	Velika Britanija	1

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

ANOVA testiranje u Tablici 5. prikazuje da empirijske p-vrijednosti za varijable *Broj rođenih, Broj umrlih, Imigracije, BDP per capita* i *Tražitelji azila* iznosi 0%, te ne premašuju graničnu signifikantnost od 5% i može se zaključiti da se sredine između predloženih klastera značajno razlikuju. Empirijske p-vrijednosti kod varijabli *Fertilitet* i *Godine zavisnosti mladog stanovništva* također su ispod granične signifikantnosti od 5%. Iznimka su varijable *Godine zavisnosti starog stanovništva* i *Stopa zaposlenosti* čije vrijednosti premašuju graničnu signifikantnost od 5%, te zbog toga ne pridonose značajnoj razlici između klastera.

Tablica 5. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 13 klastera pomoću metode k-prosjeka

ANOVA			
	df	F	Sig.
Broj rođenih (000)	14	222,257	0,000
Broj umrlih (000)	14	287,247	0,000
Imigracije (000)	14	1685,84	0,000
BDP per capita (%)	14	13,496	0,000
Fertilitet	14	2,845	0,031
Godine zavisnosti mladog stanovništva	14	3,288	0,017
Godine zavisnosti starog stanovništva	14	1,283	0,324
Tražitelji azila (000)	14	89,168	0,000
Stopa zaposlenosti	14	1,127	0,412

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

5.2.4. Klasificiranje u 12 klastera

I dalje nastavljamo s prikazivanjem rezultata klasificiranja. Sada su prikazani rezultati klasificiranja u 12 klastera koji su se pojavili 7 puta (dakle, više od 60% puta od ukupnog broja klasificiranja u 12 klastera).

Izvršeno je grupiranje 28 zemalja Europske unije prema 9 odgovarajućih demografskih pokazatelja za 2015. godinu koristeći nehijerarhijsku metodu k-prosjeka.

Smanjenje broja klastera sa 13 na 12 utjecalo je na promjenu u grupi Bugarske, Češke, Grčke i Portugala jer im se sada pridružila Danska koja je ranije bila klasificirana kao slična s Irskom. Po svojim demografskim karakteristikama Irska se sada svrstala u grupu Hrvatske, Estonije, Cipra, Litve, Latvije, Malte, Slovenije, Slovačke i Finske. Belgija, Nizozemska, Austrija i Švedska tvore jednu grupu kao i kod klasificiranja u 13 klastera. Ostale države članice tvore zasebne klastere. Svi podaci vidljivi su u Tablici 6.

Tablica 6. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 12 klastera pomoću metode k-prosjeka

Cluster Membership		
Case Number	Država	Cluster
1	Belgija	1
2	Bugarska	8
3	Češka	8
4	Danska	8
5	Njemačka	5
6	Estonija	6
7	Irska	6
8	Grčka	8
9	Španjolska	9
10	Francuska	10
11	Hrvatska	6
12	Italija	12
13	Cipar	6
14	Litva	6
15	Latvija	6
16	Luksemburg	3
17	Mađarska	2
18	Malta	6
19	Nizozemska	1
20	Austrija	1
21	Poljska	11
22	Portugal	8
23	Rumunjska	4
24	Slovenija	6
25	Slovačka	6
26	Finska	6
27	Švedska	1
28	Velika Britanija	7

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

Smanjenje broja klastera sa 12 na 13 utjecalo je na ANOVA testiranje čiji se rezultati nalaze u Tablici 7. Došlo je do povećanja broja varijabli čije empirijske p-vrijednosti značajno premašuju graničnu signifikantnost od 5%. Uz varijable *Godine zavisnosti starog stanovništva* i *Stopa zaposlenosti*, varijable *Godine zavisnosti mladog stanovništva* i *Fertilitet* također imaju signifikantnost veću od 5%, što nam govori da te varijable ne pridonose značajnoj razlici između klastera. Kod ostatka varijabli, empirijske p-vrijednosti nalaze se značajno ispod 5%.

Tablica 7. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 12 klastera pomoću metode k-prosjeka

ANOVA			
	df	F	Sig.
Broj rođenih (000)	16	234,609	0,000
Broj umrlih (000)	16	254,979	0,000
Imigracije (000)	16	531,958	0,000
BDP per capita (%)	16	4,447	0,004
Fertilitet	16	1,445	0,244
Godine zavisnosti mladog stanovništva	16	0,753	0,678
Godine zavisnosti starog stanovništva	16	1,502	0,223
Tražitelji azila (000)	16	30,123	0,000
Stopa zaposlenosti	16	1,003	0,484

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

5.2.5. Klasificiranje u 11 klastera

U Tablici 8. i Tablici 9. prikazani su rezultati klasificiranja u 11 klastera koji su se pojavili 6 puta (dakle, više od 60% puta od ukupnog broja klasificiranja u 11 klastera).

Koristeći nehijerarhijsku metodu k-prosjeka klasificirano je 28 zemalja Europske unije prema 9 odgovarajućih demografskih pokazatelja za 2015. Godinu.

Iz Tablice 8. vidljivo je da 9 zemalja članica EU-28 tvori zasebne grupe tvori zasebne grupe (Njemačka, Španjolska, Francuska, Italija, Luksemburg, Mađarska, Poljska, Rumunjska i Velika Britanija), dok su ostale zemlje raspoređene u još samo dvije grupe. Jednu grupu tvori čak 15 zemalja, a to su: Bugarska, Češka, Danska, Estonija, Irska, Grčka, Hrvatska, Cipar, Litva, Latvija, Malta, Portugal, Slovenija, Slovačka i Finska. U drugu grupu svrstale su se Belgija, Nizozemska, Austrija i Švedska, koje tvore jednu grupu kao i kod klasificiranja u 12 i 13 klastera.

Tablica 8. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 11 klastera pomoću metode k-prosjeka

Cluster Membership		
Case Number	Država	Cluster
1	Belgija	1
2	Bugarska	6
3	Češka	6
4	Danska	6
5	Njemačka	5
6	Estonija	6
7	Irska	6
8	Grčka	6
9	Španjolska	9
10	Francuska	10
11	Hrvatska	6
12	Italija	8
13	Cipar	6
14	Litva	6
15	Latvija	6
16	Luksemburg	7
17	Mađarska	11
18	Malta	6
19	Nizozemska	1
20	Austrija	1
21	Poljska	4
22	Portugal	6
23	Rumunjska	3
24	Slovenija	6
25	Slovačka	6
26	Finska	6
27	Švedska	1
28	Velika Britanija	2

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

Iz rezultata prikazanih u Tablici 9., a dobivenih ANOVA testiranjem klaster metodom k-prosjeka zaključujemo kako empirijske p-vrijednosti varijabli *Godine zavisnosti starog stanovništva, Stopa zaposlenosti, Godine zavisnosti mladog stanovništva* i *Fertilitet* i dalje značajno premašuju graničnu signifikantnost od 5%, što nam govori da ne pridonose značajnoj razlici između klastera. Empirijske p-vrijednosti za varijable *Broj rođenih, Broj umrlih, Imigracije,* i *Tražitelji azila* iznose 0%, te ne premašuju graničnu signifikantnost od

5% i može se zaključiti da se sredine između predloženih klastera značajno razlikuju. Empirijska p-vrijednost kod varijable *BDP per capita* iznosi 0,2% što je također ispod granične signifikantnosti od 5%.

Tablica 9. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 11 klastera pomoću metode k-prosjeka

ANOVA			
	df	F	Sig.
Broj rođenih (000)	17	144,01	0,000
Broj umrlih (000)	17	103,18	0,000
Imigracije (000)	17	485,253	0,000
BDP per capita (%)	17	5,112	0,002
Fertilitet	17	1,547	0,206
Godine zavisnosti mladog stanovništva	17	0,827	0,61
Godine zavisnosti starog stanovništva	17	1,076	0,429
Tražitelji azila (000)	17	34,65	0,000
Stopa zaposlenosti	17	1,147	0,386

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

5.2.6. Klasificiranje u 10 klastera

U nastavku su prikazani rezultati klasificiranja u 10 klastera koji su se pojavili 6 puta (dakle, više od 60% puta od ukupnog broja klasificiranja u 10 klastera), a dobiveni su nehijerarhijskom metodom k-prosjeka . Klasificirano je 28 zemalja Europske unije prema 9 odgovarajućih demografskih pokazatelja za 2015. godinu.

Klasificiranjem u 10 klastera smanjio se broj država članica EU-28 koje se ističu po svojim demografskim karakteristikama, te tvore zasebne klastere. U prethodnom slučaju bilo ih je 9, a sada imamo 6 zasebnih klastera koje tvore sljedeće zemlje: Njemačka, Francuska, Italija, Luksemburg, Rumunjska i Velika Britanija. Španjolska i Poljska, koje su se ranije klasificirale kao zasebne, sada tvore jednu grupu, a Mađarska tvori grupu sa Švedskom, koja se isključila iz grupe Belgije, Nizozemske i Austrije. Bugarska, Češka, Danska, Estonija, Irska, Grčka, Hrvatska, Cipar, Litva, Latvija, Malta, Portugal, Slovenija, Slovačka i Finska još uvijek su klasificirane kao najsličnije po svojim demografskim karakteristikama, te tvore jednu grupu. Svi dobiveni zaključci napisani su na temelju Tablice 10.

Tablica 10. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 10 klastera pomoću metode k-prosjeka

Cluster Membership		
Case Number	Država	Cluster
1	Belgija	1
2	Bugarska	6
3	Češka	6
4	Danska	6
5	Njemačka	5
6	Estonija	6
7	Irska	6
8	Grčka	6
9	Španjolska	7
10	Francuska	10
11	Hrvatska	6
12	Italija	3
13	Cipar	6
14	Litva	6
15	Latvija	6
16	Luksemburg	8
17	Mađarska	4
18	Malta	6
19	Nizozemska	1
20	Austrija	1
21	Poljska	7
22	Portugal	6
23	Rumunjska	2
24	Slovenija	6
25	Slovačka	6
26	Finska	6
27	Švedska	4
28	Velika Britanija	9

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

Tablica 11. rezultat je ANOVA testiranja klaster metodom k-prosjeka. Što se tiče varijabli *Broj rođenih, Broj umrlih, Imigracije, Tražitelji azila* i *BDP per capita* rezultati ostaju identični onima dobivenim u prethodnom klasificiranju, tj. klasificiranju 11 klastera. Dok su se empirijske p-vrijednosti za varijable *Godine zavisnosti starog stanovništva, Stopa zaposlenosti, Godine zavisnosti mladog stanovništva* i *Fertilitet* dodatno povećale te i dalje

značajno premašuju graničnu signifikantnost od 5%, iz čega se zaključuje da se sredine između predloženih klastera razlikuju.

Tablica 11. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 10 klastera pomoću metode k-prosjeka

ANOVA			
	df	F	Sig.
Broj rođenih (000)	18	157,83	0,000
Broj umrlih (000)	18	117,783	0,000
Imigracije (000)	18	265,26	0,000
BDP per capita (%)	18	5,046	0,002
Fertilitet	18	1,541	0,207
Godine zavisnosti mladog stanovništva	18	0,788	0,631
Godine zavisnosti starog stanovništva	18	1,045	0,445
Tražitelji azila (000)	18	148,321	0,000
Stopa zaposlenosti	18	1,139	0,387

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

5.2.7. Klasificiranje u 8 klastera

U prikazanom slučaju korištena je nehijerarhijska metoda k-prosjeka. Izvršeno je grupiranje 28 zemalja Europske unije prema 9 odgovarajućih demografskih pokazatelja za 2015. godinu.

Ovo su rezultati klasificiranja u 8 klastera koji su se pojavili 5 puta (dakle, više od 60% puta od ukupnog broja klasificiranja u 8 klastera).

Kao što je vidljivo iz Tablice 12. klasificiranjem u 8 klastera pojavile su se 2 velike grupe zemalja od kojih jednu čine Belgija, Bugarska, Češka, Grčka, Mađarska, Nizozemska, Austrija, Portugal i Švedska, dok drugu veću grupu čine Danska, Estonija, Irska, Hrvatska, Cipar, Litva, Latvija, Luksemburg, Malta, Slovenija, Slovačka i Finska. Kao slične po svojim demografskim karakteristikama svrstale su se Španjolska i Poljska, dok se ostalih 5 zemalja i dalje izdvaja u zasebne klastere.

Tablica 12. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 8 klastera pomoću metode k-prosjeka

Cluster Membership		
Case Number	Država	Cluster
1	Belgija	7
2	Bugarska	7
3	Češka	7
4	Danska	6
5	Njemačka	5
6	Estonija	6
7	Irska	6
8	Grčka	7
9	Španjolska	8
10	Francuska	4
11	Hrvatska	6
12	Italija	3
13	Cipar	6
14	Litva	6
15	Latvija	6
16	Luksemburg	6
17	Mađarska	7
18	Malta	6
19	Nizozemska	7
20	Austrija	7
21	Poljska	8
22	Portugal	7
23	Rumunjska	1
24	Slovenija	6
25	Slovačka	6
26	Finska	6
27	Švedska	7
28	Velika Britanija	2

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

U Tablici 13. prikazano je ANOVA testiranja klaster metodom k-prosjeka. Smanjenje broja klastera na 8 dovelo je do povećanja broja varijabli čije empirijske vrijednosti prelaze graničnu signifikantnost od 5%. Uz varijable *Godine zavisnosti starog stanovništva, Stopa zaposlenosti, Godine zavisnosti mladog stanovništva* i *Fertilitet*, varijabla *BDP per capita* u ovom slučaju značajno prelazi graničnu signifikantnost od 5% iz čega se zaključuje da se sredine između predloženih klastera značajno ne razlikuju. Rezultati signifikantnosti za varijable *Broj rođenih, Broj umrlih, Imigracije, Tražitelji azila* ostaju 0%, te kao takve pridonose značajnoj razlici između klastera.

Tablica 13. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 8 klastera pomoću metode k-prosjeka

ANOVA			
	df	F	Sig.
Broj rođenih (000)	20	318,044	0,000
Broj umrlih (000)	20	560,21	0,000
Imigracije (000)	20	159,446	0,000
BDP per capita (%)	20	0,251	0,966
Fertilitet	20	1,901	0,123
Godine zavisnosti mladog stanovništva	20	1,167	0,364
Godine zavisnosti starog stanovništva	20	1,459	0,238
Tražitelji azila (000)	20	14,728	0,000
Stopa zaposlenosti	20	1,155	0,371

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

5.2.8. Klasificiranje u 6 klastera

Sada se prikazuju rezultati klasificiranja u 6 klastera koji su se pojavili 4 puta (dakle, više od 60% puta od ukupnog broja klasificiranja u 6 klastera).

I u ovom slučaju korištena je nehijerarhijska metoda K-prosjeka. Izvršeno je grupiranje 28 zemalja Europske unije prema 9 odgovarajućih demografskih pokazatelja za 2015. godinu.

Klasifikacijom u 6 klastera dolazi do znatnih promjena među grupama. Tako sada jednu grupu čine, Belgija, Bugarska, Češka, Grčka, Hrvatska, Mađarska, Nizozemska, Austrija, Portugal, Slovačka, Finska i Švedska. Ovog puta kao slične po demografskim karakteristikama klasificirale su se Danska, Estonija, Irska, Cipar, Litva, Latvija, Luksemburg, Malta i Slovenija. Francuska i Velika Britanija sada tvore jednu grupu, a Poljska, Rumunjska i Španjolska drugu. Njemačka i Italija tvore zasebne klastere. Sve navedeno prikazano je u Tablici 14.

Tablica 14. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 6 klastera pomoću metode k-prosjeka

Cluster Membership		
Case Number	Država	Cluster
1	Belgija	6
2	Bugarska	6
3	Češka	6
4	Danska	4
5	Njemačka	5
6	Estonija	4
7	Irska	4
8	Grčka	6
9	Španjolska	3
10	Francuska	2
11	Hrvatska	6
12	Italija	1
13	Cipar	4
14	Litva	4
15	Latvija	4
16	Luksemburg	4
17	Mađarska	6
18	Malta	4
19	Nizozemska	6
20	Austrija	6
21	Poljska	3
22	Portugal	6
23	Rumunjska	3
24	Slovenija	4
25	Slovačka	6
26	Finska	6
27	Švedska	6
28	Velika Britanija	2

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

Što se tiče rezultata ANOVA testiranja klaster metodom k-prosjeka prikazanih u Tablici 15. signifikantnosti za varijable *Broj rođenih, Broj umrlih, Imigracije, Tražitelji azila* ostaju 0%, te kao takve pridonose značajnoj razlici između klastera. No i dalje prevladava broj varijabli čije empirijske p-vrijednosti premašuju graničnu signifikantnost od 5% iz čega se zaključuje da se sredine između predloženih klastera značajno ne razlikuju.

Tablica 15. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 6 klastera pomoću metode k-prosjeka

ANOVA			
	df	F	Sig.
Broj rođenih (000)	22	137,468	0,000
Broj umrlih (000)	22	240,614	0,000
Imigracije (000)	22	99,299	0,000
BDP per capita (%)	22	,569	0,723
Fertilitet	22	2,533	0,059
Godine zavisnosti mladog stanovništva	22	1,846	0,145
Godine zavisnosti starog stanovništva	22	1,895	0,136
Tražitelji azila (000)	22	18,974	0,000
Stopa zaposlenosti	22	1,705	0,175

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

5.2.9. Klasificiranje u 9 klastera

Na temelju prethodno prikazanih rezultata vidljivo je kako smanjenjem broja klastera ispod 9 dolazi do značajnih promjena u klasterima, te raste broj varijabli koje premašuju graničnu signifikantnost od 5%. Stoga, u nastavku rada prikazano je još samo klasificiranje u 9 klastera kao optimalno rješenje.

Temeljni razlog odabira klasificiranja zemalja EU-28 u 9 klastera su stabilni konačni rezultati klasificiranja i pri smanjenju broja kriterija.

Potrebno je napomenuti da pri klasteriranju u manje od 9 klastera metodologija višekriterijskog klasificiranja na temelju demografskih pokazatelja sugerira izostavljanje pokazatelja BDP po stanovniku u postotku kao kriterija klasificiranja. To je neprihvatljivo i predstavlja još jedan argument izbora klasteriranja u 9 klastera kao optimalnog.

Uspoređujući dobivene rezultate klasificiranja zemalja EU-28 u različit broj klastera može se zaključiti da je neizbježno da se 5 zemalja članica EU-28 uvijek nalazi u zasebnim klaserima, a njih 9 se uvijek drži zajedno.

Kako bi se detaljnije obrazložilo razloge odabira klasificiranja u 9 klastera kao optimalnog rješenja, u nastavku će biti prikazani rezultati klasificiranja hijerarhijskom i nehijerarhijskom

metodom, koristeći 9 i 5 demografskih pokazatelja kao kriterije klasificiranja za svaku od metoda.

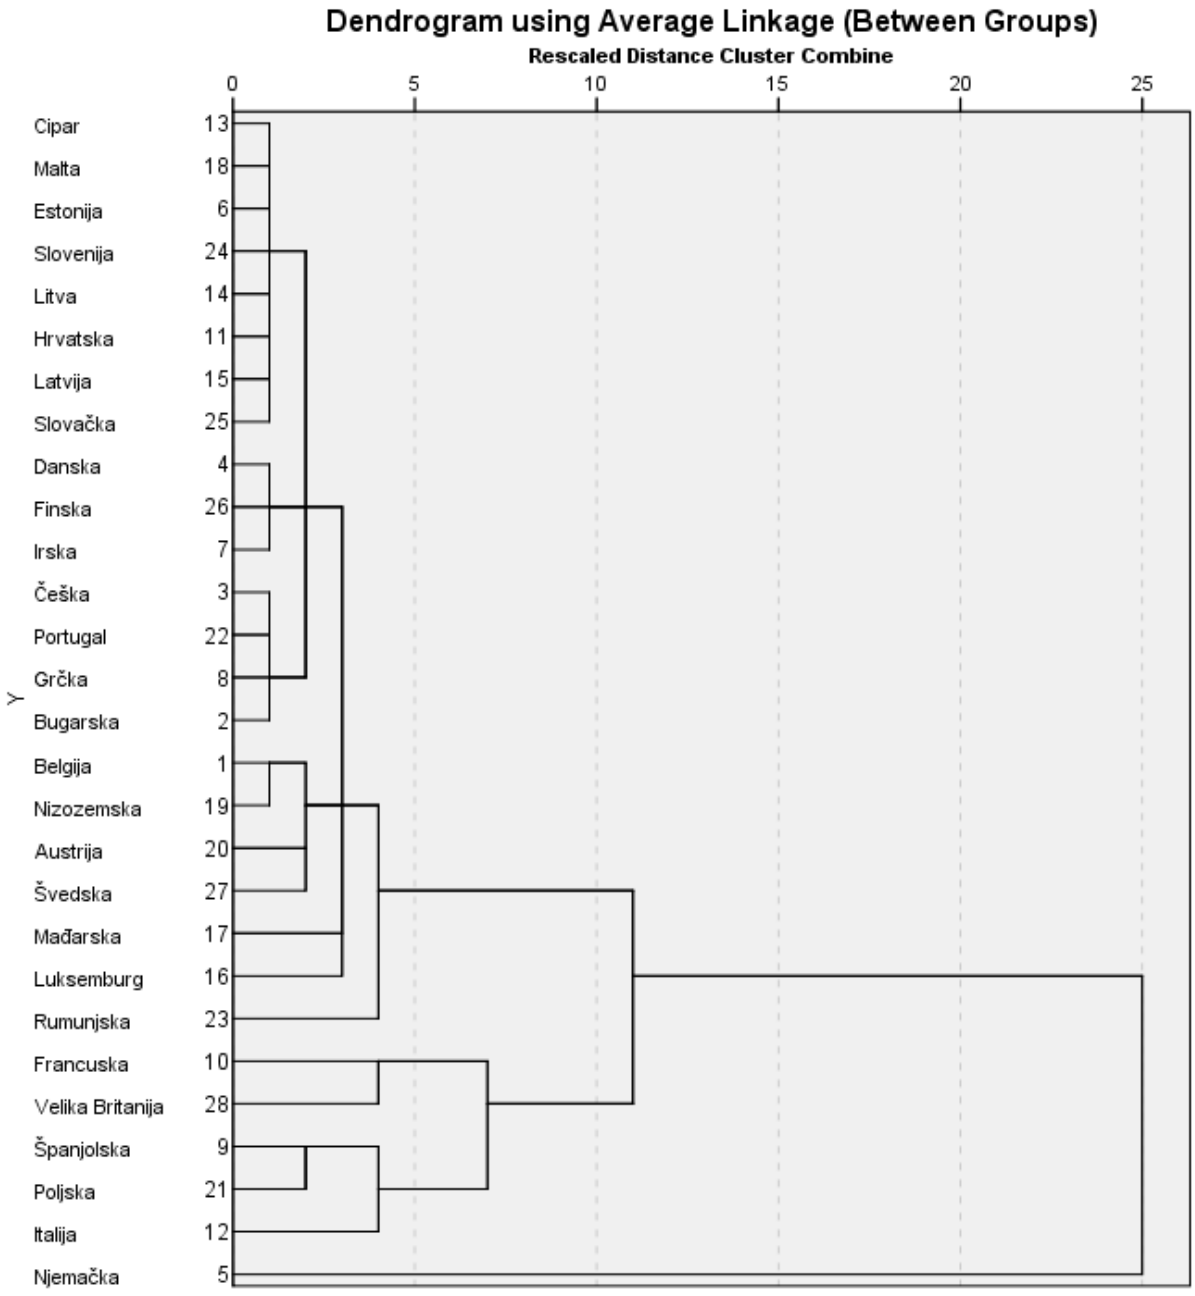
Prilikom smanjenja broja varijabli, izbačene varijable su one čija je signifikantnost u prethodnim rezultatima klasificiranja bila veća od 5%, a to su *Fertilitet, Godine zavisnosti mladog stanovništva, Godine zavisnosti starog stanovništva* i *Stopa zaposlenosti.* Odnosno, prilikom klasificiranja s 5 varijabli, varijable uzete u obzir su *Broj rođenih, Broj umrlih, Imigracije, BDP per capita* i *Tražitelji azila.*

Također, u nastavku će se donijeti zaključci o prihvaćanju ili odbacivanju postavljenih hipoteza.

5.2.9.1. Klasificiranje u 9 klastera hijerarhijskom metodom

a) U prikazanom slučaju korištena je hijerarhijska metoda udruživanja ili aglomerativna metoda, a izvršeno je grupiranje 28 zemalja Europske unije prema 9 odgovarajućih demografskih pokazatelja za 2015. godinu.

Kao što je prikazano na dendogramu Danska, Finska i Irska klasificirane su zajedno u jednu grupu. Hrvatska je klasificirana kao slična s Estonijom, Ciprom, Latvijom, Litvom, Maltom, Slovenijom i Slovačkom, a Bugarska i Češka tvore grupu zajedno sa Grčkom i Portugalom. Najmanju grupu tvore Nizozemska i Belgija, dok se ostale zemlje članice Europske unije, prema demografskim karakteristikama, klasificiraju kao zasebne.



Slika 3. Klasifikacija zemalja EU-28 u 9 klastera prema 9 demografskih značajki u 2015. godini pomoću dendograma

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

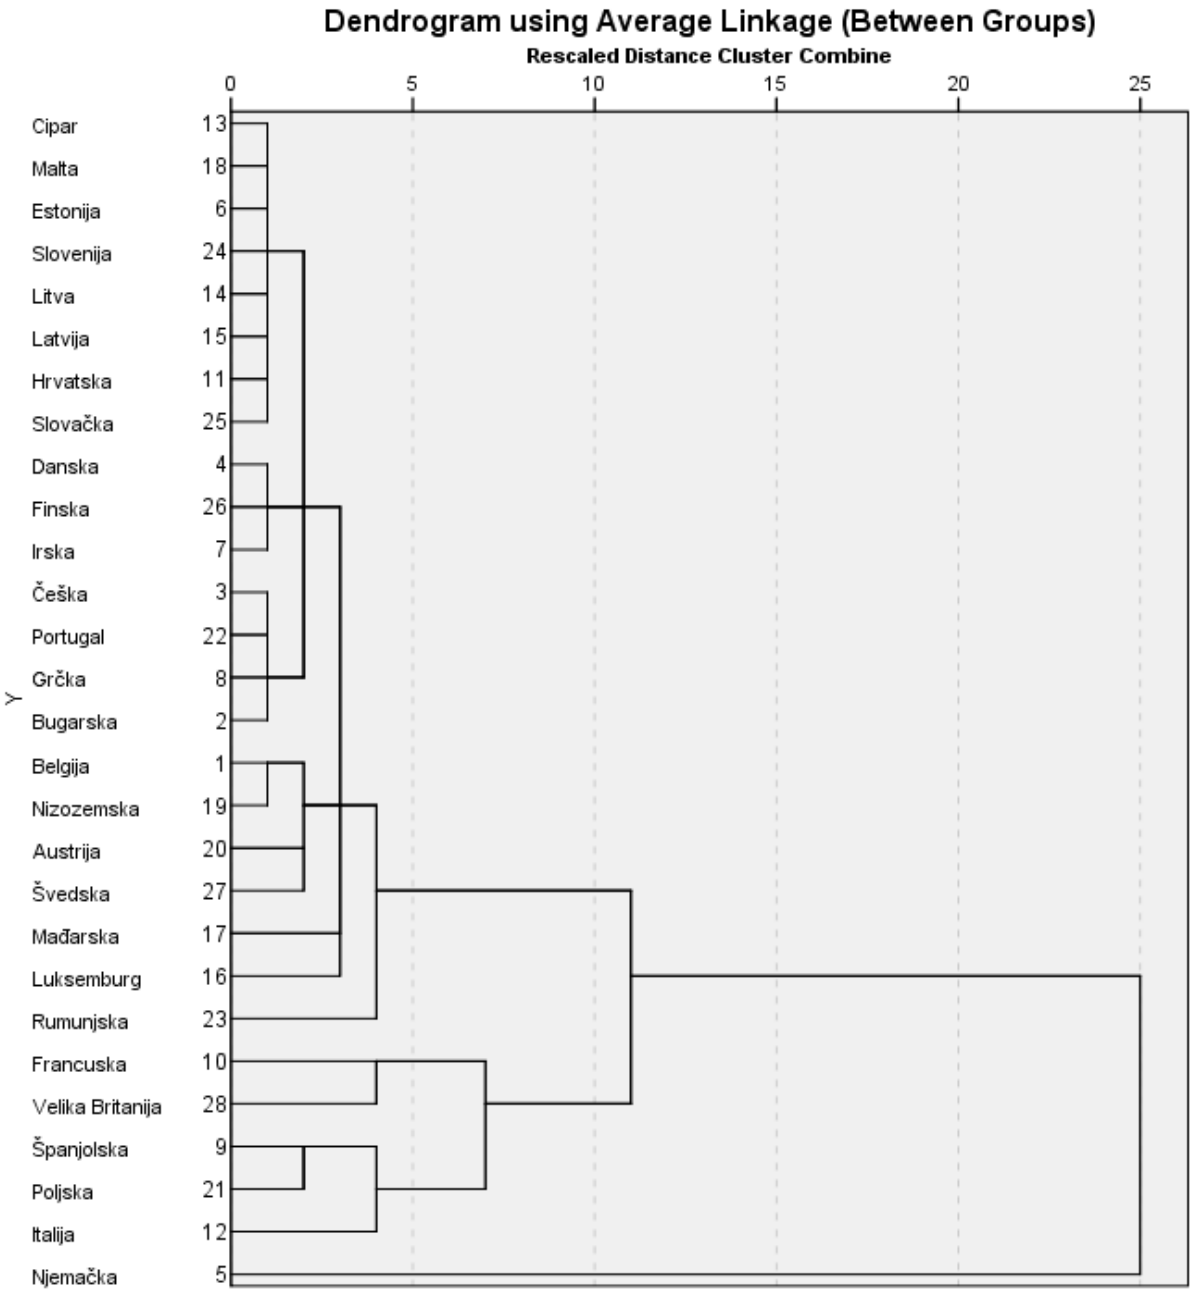
Iz Tablice 16. može se vidjeti da su Belgija, Nizozemska, Švedska, Austrija i Mađarska po demografskim karakteristikama jako slične jer se drže čvrsto zajedno, bez obzira na promjenu broja klastera, dok se Njemačka uvijek klasificira kao zasebna. Promjena broja klastera utječe na grupiranje svih ostalih zemalja članica EU.

Tablica 16. Klasifikacija zemalja EU-28 prema 9 demografskih značajki u 2015. godini u 2 do 9 klastera pomoću hijerarhijske metode

Cluster Membership								
Case	9 Clusters	8 Clusters	7 Clusters	6 Clusters	5 Clusters	4 Clusters	3 Clusters	2 Clusters
1:Belgija	1	1	1	1	1	1	1	1
2:Bugarska	2	1	1	1	1	1	1	1
3:Češka	2	1	1	1	1	1	1	1
4:Danska	2	1	1	1	1	1	1	1
5:Njemačka	3	2	2	2	2	2	2	2
6:Estonija	2	1	1	1	1	1	1	1
7:Irska	2	1	1	1	1	1	1	1
8:Grčka	2	1	1	1	1	1	1	1
9:Španjolska	4	3	3	3	3	3	3	1
10:Francuska	5	4	4	4	4	4	3	1
11:Hrvatska	2	1	1	1	1	1	1	1
12:Italija	6	5	5	5	5	3	3	1
13:Cipar	2	1	1	1	1	1	1	1
14:Litva	2	1	1	1	1	1	1	1
15:Latvija	2	1	1	1	1	1	1	1
16:Luksemburg	7	6	1	1	1	1	1	1
17:Mađarska	1	1	1	1	1	1	1	1
18:Malta	2	1	1	1	1	1	1	1
19:Nizozemska	1	1	1	1	1	1	1	1
20:Austrija	1	1	1	1	1	1	1	1
21:Poljska	4	3	3	3	3	3	3	1
22:Portugal	2	1	1	1	1	1	1	1
23:Rumunjska	8	7	6	1	1	1	1	1
24:Slovenija	2	1	1	1	1	1	1	1
25:Slovačka	2	1	1	1	1	1	1	1
26:Finska	2	1	1	1	1	1	1	1
27:Švedska	1	1	1	1	1	1	1	1
28:Velika Britanija	9	8	7	6	4	4	3	1

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

b) U prikazanom slučaju korištena je hijerarhijska metoda udruživanja ili aglomerativna metoda, a izvršeno je grupiranje 28 zemalja Europske unije prema 5 odgovarajućih demografskih pokazatelja za 2015. godinu.



Slika 4. Klasifikacija zemalja EU-28 u 9 klastera prema 5 demografskih značajki u 2015. godini pomoću dendograma

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

Uspoređujući Sliku 3. i Sliku 4. koje su dobivene prilikom grupiranja EU-28 zemalja prema 5 demografskih pokazatelja (Slika 4.) i prema 9 demografskih pokazatelja (Slika 3.) koristeći hijerarhijsku metodu vidljivo je da su prikazani dendogrami identični, te nam to dokazuje stabilnost rezultata bez obzira na smanjenje broja demografskih kriterija.

Tablica 17. Klasifikacija zemalja EU-28 prema 5 demografskih značajki u 2015. godini u 2 do 9 klastera pomoću hijerarhijske metode

Cluster Membership								
Case	9 Clusters	8 Clusters	7 Clusters	6 Clusters	5 Clusters	4 Clusters	3 Clusters	2 Clusters
1:Belgija	1	1	1	1	1	1	1	1
2:Bugarska	2	1	1	1	1	1	1	1
3:Češka	2	1	1	1	1	1	1	1
4:Danska	2	1	1	1	1	1	1	1
5:Njemačka	3	2	2	2	2	2	2	2
6:Estonija	2	1	1	1	1	1	1	1
7:Irska	2	1	1	1	1	1	1	1
8:Grčka	2	1	1	1	1	1	1	1
9:Španjolska	4	3	3	3	3	3	3	1
10:Francuska	5	4	4	4	4	4	3	1
11:Hrvatska	2	1	1	1	1	1	1	1
12:Italija	6	5	5	5	5	3	3	1
13:Cipar	2	1	1	1	1	1	1	1
14:Litva	2	1	1	1	1	1	1	1
15:Latvija	2	1	1	1	1	1	1	1
16:Luksemburg	7	6	1	1	1	1	1	1
17:Mađarska	1	1	1	1	1	1	1	1
18:Malta	2	1	1	1	1	1	1	1
19:Nizozemska	1	1	1	1	1	1	1	1
20:Austrija	1	1	1	1	1	1	1	1
21:Poljska	4	3	3	3	3	3	3	1
22:Portugal	2	1	1	1	1	1	1	1
23:Rumunjska	8	7	6	6	1	1	1	1
24:Slovenija	2	1	1	1	1	1	1	1
25:Slovačka	2	1	1	1	1	1	1	1
26:Finska	2	1	1	1	1	1	1	1
27:Švedska	1	1	1	1	1	1	1	1
28:Velika Britanija	9	8	7	4	4	4	3	1

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

Iz priloženog je vidljivo kako Tablica 17. pokazuje identične rezultate kao i Tablica 16. pa se zaključuje da promjena broja kriterija klasificiranja, u ovom slučaju smanjene broja varijabli s 9 na 5, neće utjecati na promjenu u grupiranju zemalja članica EU-28. Ovim se još jednom potvrđuje da je odabrano klasificiranje (klasificiranje u 9 klastera) optimalno.

5.2.9.2. Klasificiranje u 9 klastera nehijerarhijskom metodom

a) U prikazanom slučaju korištena je nehijerarhijska metoda k-prosjeka. Izvršeno je grupiranje 28 zemalja Europske unije prema 9 odgovarajućih demografskih pokazatelja za 2015. godinu.

Kao što prikazuje Tablica 18. Belgija, Mađarska, Austrija i Rumunjska tvore jedan klaster. Kao slične po svojim demografskim karakteristikama u jednu grupu svrstane su Španjolska i Poljska, dok su se u drugu grupu svrstale Mađarska i Švedska. Najveću grupu čine Bugarska, Češka, Danska, Estonija, Irska, Grčka, Hrvatska, Cipar, Litva, Latvija, Malta, Portugal, Slovenija, Slovačka i Finska.

Uspoređujući Tablicu 18. sa svim prethodno dobivenim rezultatima, možemo zaključiti kako se Njemačka, Francuska, Italija, Luksemburg i Velika Britanija uvijek izdvajaju u zasebne klastere, te ni u jednom slučaju nisu bile klasificirane kao slične, po svojim demografskim obilježjima, sa nekim od ostalih zemalja članica EU-28. S obzirom na navedeno može se prihvatiti hipoteza H_2 - većina zemalja osnivačica EU s obzirom na demografske pokazatelje izdvaja se u posebne klastere.

Tablica 18. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 9 klastera pomoću metode k-prosjeka

Cluster Membership		
Case Number	Država	Cluster
1	Belgija	1
2	Bugarska	6
3	Češka	6
4	Danska	6
5	Njemačka	5
6	Estonija	6
7	Irska	6
8	Grčka	6
9	Španjolska	9
10	Francuska	8
11	Hrvatska	6
12	Italija	4
13	Cipar	6
14	Litva	6
15	Latvija	6
16	Luksemburg	3
17	Mađarska	2
18	Malta	6
19	Nizozemska	1
20	Austrija	1
21	Poljska	9
22	Portugal	6
23	Rumunjska	1
24	Slovenija	6
25	Slovačka	6
26	Finska	6
27	Švedska	2
28	Velika Britanija	7

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

ANOVA testiranja klaster metodom k-prosjeka prikazano je u Tablici 19. Kao i kod klasificiranja u 12, 11 i 10 klastera, empirijske p-vrijednosti varijabli *Broj rođenih, Broj umrlih, Imigracije, Tražitelji azila* i *BDP per capita* nalaze se ispod granične signifikantnosti od 5% i može se zaključiti da se sredine između predloženih klastera značajno razlikuju. Dok empirijske p-vrijednosti za varijable *Godine zavisnosti starog stanovništva, Stopa zaposlenosti, Godine zavisnosti mladog stanovništva* i *Fertilitet* i dalje značajno premašuju graničnu signifikantnost od 5%, iz čega zaključujemo da ne pridonose značajnoj razlici između klastera.

Tablica 19. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 9 klastera pomoću metode k-prosjeka

ANOVA			
	df	F	Sig.
Broj rođenih (000)	19	164,837	0,000
Broj umrlih (000)	19	85,144	0,000
Imigracije (000)	19	305,978	0,000
BDP per capita (%)	19	4,427	0,004
Fertilitet	19	1,823	0,135
Godine zavisnosti mladog stanovništva	19	0,913	0,526
Godine zavisnosti starog stanovništva	19	1,184	0,358
Tražitelji azila (000)	19	98,783	0,000
Stopa zaposlenosti	19	1,159	0,372

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

b) U prikazanom slučaju korištena je nehijerarhijska metoda k-prosjeka. Izvršeno je grupiranje 28 zemalja Europske unije prema 5 odgovarajućih demografskih pokazatelja za 2015. godinu.

Tablica 20. prikazuje rezultate klasteriranja 28 zemalja Europske unije na osnovu 5 odabranih demografskih pokazatelja. Uspoređujući Tablicu 20. i Tablicu 18. zaključujemo kako smanjenje broja pokazatelja nije utjecalo na promjene kod klasificiranja. Važno je naglasiti da Njemačka, Francuska, Italija, Luksemburg i Velika Britanija tvore zasebne klastere.

U Tablici 21. prikazan je BDP po stanovniku u svakoj zemlji članici EU-28 prema PPS-u. Indeks obujma BDP-a po glavi stanovnika u PPS-u izražava se u odnosu na prosjek EU-28 koji iznosi 100. Ako je indeks države viši / niži od 100, razina BDP-a te države po glavi stanovnika nalazi se iznad / ispod prosjeka EU-28. Svrha indeksa je usporedba između zemalja. Luksemburg, Irska, Nizozemska, Austrija, Njemačka, Danska, Švedska, Belgija, Velika Britanija, Finska i Francuska zemlje su čiji se BDP po stanovniku nalazi iznad prosjeka EU-28. S obzirom da sve navedene zemlje ne tvore zasebne klastere, a Italija koja tvori zaseban klaster ne spada među zemlje s visokim BDP-om po stanovniku, hipotezu H_3 - zemlje s najvišim BDP-om po stanovniku izdvajaju se u zasebne klastere – odbacujemo.

Tablica 20. Klasifikacija 28 zemalja Europske unije na temelju 5 odabranih demografskih pokazatelja u 9 klastera pomoću metode k-prosjeka

Cluster Membership		
Case Number	Država	Cluster
1	Belgija	1
2	Bugarska	6
3	Češka	6
4	Danska	6
5	Njemačka	5
6	Estonija	6
7	Irska	6
8	Grčka	6
9	Španjolska	9
10	Francuska	8
11	Hrvatska	6
12	Italija	4
13	Cipar	6
14	Litva	6
15	Latvija	6
16	Luksemburg	3
17	Mađarska	2
18	Malta	6
19	Nizozemska	1
20	Austrija	1
21	Poljska	9
22	Portugal	6
23	Rumunjska	1
24	Slovenija	6
25	Slovačka	6
26	Finska	6
27	Švedska	2
28	Velika Britanija	7

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

Tablica 21. BDP po stanovniku u svakoj zemlji članici EU-28 u 2015. godini

Države	BDP po stanovniku
Luksemburg	270,1
Irska	172,2
Nizozemska	127,8
Austrija	127,1
Njemačka	125,0
Danska	123,3
Švedska	122,9
Belgija	117,0
Velika Britanija	109,7
Finska	108,3
Francuska	105,2
Italija	95,1
Španjolska	91,3
Malta	88,2
Češka	86,8
Slovenija	82,3
Cipar	80,9
Portugal	77,1
Slovačka	76,4
Estonija	73,6
Latvija	73,3
Grčka	70,5
Poljska	68,4
Mađarska	67,7
Litva	64,2
Hrvatska	58,0
Rumunjska	56,6
Bugarska	46,2

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

ANOVA testiranje u Tablici 22. pokazuje da empirijske p-vrijednosti varijabli *Broj rođenih, Broj umrlih, Imigracije, BDP per capita* i *Tražitelji azila* ne premašuju graničnu signifikantnost od 5%, te se može zaključiti da se sredine između predloženih klastera značajno razlikuju.

Tablica 22. Analiza varijance (ANOVA) na temelju 5 odabranih demografskih pokazatelja u 9 klastera pomoću metode k-prosjeka

ANOVA			
	df	F	Sig.
Broj rođenih (000)	19	164,837	0,000
Broj umrlih (000)	19	85,144	0,000
Imigracije (000)	19	305,978	0,000
BDP per capita (%)	19	4,427	0,004
Tražitelji azila (000)	19	98,783	0,000

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

Na temelju svih prethodno prikazanih rezultata klasificiranja u 9 klastera, koristeći hijerarhijsku i nehijerarhijsku metodu, jasno je vidljivo kako Njemačka, Francuska, Italija, Luksemburg i Velika Britanija uvijek tvore zasebne klastere, dok su Bugarska, Češka, Danska, Estonija, Irska, Grčka, Hrvatska, Cipar, Litva, Latvija, Malta, Portugal, Slovenija, Slovačka i Finska slične po svojim demografskim karakteristikama, te tvore jedan klaster. Ostale zemlje članice EU-28 svrstavaju se u još svega 3 klastera, te možemo prihvatiti hipotezu H_1 - zemlje EU-28 se po demografskim pokazateljima mogu svrstati u manji broj klastera.

U Tablici 23. prikazan je broj osoba koje su zatražile azil u zemljama EU-28, a dolaze iz zemalja izvan EU-28 u 2015. godini. Iz tablice je vidljivo da se najveći broj azila zatražio u Njemačkoj, Mađarskoj, Švedskoj, Austriji, Italiji i Francuskoj. S obzirom da Njemačka, Italija i Francuska tvore zasebne klastere, a Mađarska, Švedska i Austrija nisu klasificirane kao slične i ne tvore zajednički klaster, odbacujemo hipotezu H_4 - tražitelji azila preferiraju zemlje EU-28 koje se nalaze u samo nekoliko klastera formiranih na temelju njihovih demografskih karakteristika.

Tablica 23. Broj osoba koje su zatražile azil u zemljama EU-28, a dolaze iz zemalja izvan EU-28 u 2015. godini

Države	Broj tražitelja azila (000)
Njemačka	441,8
Mađarska	174,4
Švedska	156,1
Austrija	85,5
Italija	83,2
Francuska	70,6
Nizozemska	43,0
Velika Britanija	39,7
Belgija	39,0
Finska	32,2
Danska	20,8
Bugarska	20,2
Španjolska	14,6
Grčka	11,4
Poljska	10,3
Irska	3,3
Luksemburg	2,4
Cipar	2,1
Malta	1,7
Češka	1,2
Rumunjska	1,2
Portugal	0,9
Latvija	0,3
Slovačka	0,3
Litva	0,3
Slovenija	0,3
Estonija	0,2
Hrvatska	0,1

Izvor: Izrada autora prema http://ec.europa.eu/eurostat

6. ZAKLJUČAK

Demografske značajke u znatnoj mjeri utječu na socijalnu politiku koja podrazumijeva državnu preraspodjelu nacionalnog dohotka usmjerenu na prevladavanje socijalnih rizika, smanjenje socijalnih nejednakosti te ujednačavanje životnih uvjeta građana.

Opadanje fertiliteta, starenje stanovništva, migracije, transformacija strukture i funkcija obitelji najvažniji su demografski problemi s kojima se susreće Europska unija, a utječu na gospodarske i socijalne probleme, a samim time i na način provođenja aktivne demografske politike.

U radu su se teorijski i empirijski analizirali demografski i statistički pokazatelja prema popisima stanovništva Europske unije. Proučavane su sve demografske značajke zemalja EU-28 koje prati njihova službena statistika i to u svim promatranim zemljama. Svi korišteni podaci preuzeti su sa Eurostata, te se odnose na 2015. godinu, koja je trenutno najkasnija godina za koju su poznati i dostupni podaci za sve zemlje Europske unije.

Glavni cilj ovog rada bio je grupiranje zemalja članica Europske unije u homogene grupe (klastere) s obzirom na njihova demografska obilježja, stoga je provedena multivarijacijska Cluster analiza.

U obzir su uzete demografske varijable koje najznačajnije utječu na gospodarske i socijalne probleme, a samim time i na način provođenja aktivne demografske politike. Na temelju odabranih varijabli i uzorku od 28 zemalja članica Europske unije u 2015. godini, provedena je Cluster analiza, te su se primjenile hijerarhijske i nehijerarhijske metode. No zbog načela usporedne analize klasificiranja ustrajalo se na izboru „Between Groups“ za „Average Linkage“ kao i na Euklidskoj distanci pri izboru vrte udaljenosti. Analiza osjetljivosti rezultata na promjenu broja klastera kao značajnog inicijalnog dijela ulaznih podataka izvršena je u načelu empirijski, varirajući klastere od 15 do 5.

Budući da je izvršeno 100-tinjak procesa klasificiranja EU-28 prema njihovim raspoloživim demografskim pokazateljima na ovom mjestu nije bilo moguće prikazati sve dobivene rezultate. Stoga se prikazao po jedan output za svaki broj klastera koji se pojavio za taj određeni broj klastera najmanje 60% puta.

Provedenom multivarijacijskom Cluster analizom ustanovljeno je da se optimalno rješenje pojavljuje kod klasificiranja u 9 klastera. Razlog tome je pojava stabilnih rezultata pri smanjenju broja kriterija klasificiranja. Uspoređujući s ostalim rezultatima klasificiranja zemalja EU-28 u različiti broj klastera može se zaključiti da je neizbježno da se 5 zemalja članica EU-28 (Njemačka, Francuska, Italija, Luksemburg i Velika Britanija) uvijek nalazi u zasebnim klaserima, a njih 9 (Estonija, Hrvatska, Cipar, Litva, Latvija, Malta, Slovenija, Slovačka i Finska) se uvijek drži zajedno.

Također, vidljivo je kako čak 15 od 28 zemalja članica Europske unije tvori jedan klaster, a njih 5 tvori zasebne klastere. Iz toga se može zaključiti da se zemlje EU-28 značajno ne razlikuju po svojim demografskim obilježjima, te se potvrđuje hipoteza H_1.

Među 5 zemalja koje su se po svojim demografskim obilježjima izdvojile od svih ostalih zemalja EU-28, te tvore zasebne klastere ubrajamo Njemačku, Francusku, Italiju, Luksemburg i Veliku Britaniju. S obzirom da su sve navedene zemlje, osim Velike Britanije, od samih početaka sudjelovale u izgradnji Europske unije kakvu imamo danas, prihvatili smo hipotezu H_2. Iste te zemlje nisu se svrstale na vrh ljestvice kao zemlje s najvećim BDP-om po stanovniku stoga je hipoteza H_3 odbačena.

Kako se Europska unija danas suočava s najvećim nekontroliranim priljevom migranata i izbjeglica u svojoj povijesti, posebno se osvrnulo na pitanje koje to zemlje članice EU-28 migranti preferiraju. Provedenim istraživanjem došlo se do zaključka da zemlje koje migranti preferiraju tvore zasebne klastere ili nisu klasificirane kao slične po svojim demografskim karakteristikama, stoga se hipoteza H_4 odbacila.

Provedeno istraživanje može biti motiv državama članicama, sa sličnim karakteristikama, da usuglase zajedničke mjere aktivne demografske politike. Cilj ovoga rada bio je i stvaranje kvalitetnog analitičkog temelja za prijedlog odgovarajućih mjera populacijske politike s elementima pronatalitetne i redistribucijske politike razvoja pučanstva. S obzirom da se populacijska politika provodi na temelju postavljenih ciljeva koji se žele ostvariti, rezultati dobiveni u ovom radu mogu služiti kao smjernice za postavljanja tih ciljeva, a na kraju i za donošenje odgovarajućih mjera populacijske politike s elementima pronatalitetne i redistribucijske politike razvoja pučanstva.

Također, istraživanje bi trebalo proširiti spoznaju o utjecaju demografskih čimbenika na strukturu i razvoj kulturne, političke i socio-ekonomske sfere društva kao i na način i kvalitetu života općenito.

LITERATURA

Knjige i članci:

1. Bogunović, A. (2006): Europska unija - Stanje i perspektive, Ekonomski pregled, 57(1-2), str.31-63.
2. Breznik, D. (1988): Demografija - analiza, metodi i modeli, Centar za demografska istraživanja Instituta društvenih nauka, Beograd.
3. Čavrak, V., Družić, I., Barić, V., Grahovac, P., Gelo, T., Karaman Aksentijević, N., Mrnjavac, Ž., Obadić, A., Pašalić, Ž., Smolić, Š., Šimurina, J., Tica, J. (2011) Gospodarstvo Hrvatske, Politička kultura, Zagreb.
4. Eurostatpocketbooks (2014): Keyfigures on Europe, Belgium.
5. Friganović, M. (1987): Demografija: stanovništvo svijeta, Školska knjiga, Zagreb.
6. Hair, J. F., Anderson, R. E., Babin, B. J., Black, W. C. (2010). Multivariate data analysis: A global perspective (Vol. 7), Upper Saddle River, NJ: Pearson.
7. Jurun, E. (2007): Kvantitativne metode u ekonometriji, Ekonomski fakultet, Split.
8. Jurun, E., Pivac, S., Arnerić, J. (2006): Primijenjena ekonometrija 1 – Kvantitativne financije, Ekonomski fakultet Split, Split.
9. Jurun, E., Ratković, N. (2012): A Multivariate Analysis of Croatian Countries Entepreneurship, Croatian Operational Research Review, 3(1), 310-320.
10. Jurun, E., Ratković, N., Ujević, I. (2017): A cluster analysis of Croatian countries as the base for an active demographic policy, Croatian Operational Research Review, 8(1), 221-236.
11. Manly, B. F. (2004): Multivariate statistical methods, CRC Press, Boca Raton.
12. Mirošević, I. (2017): k-means Algorithm, KoG, 20(20), 91-98.
13. Moore, A. (2001): K-means and Hierarchical Clustering.
14. Pavlić I. (1971): Statistička teorija i primjena, Tehnička knjiga, Zagreb.
15. Perišić, A. (2014): Multivarijatna klasifikacija jedinica lokalne i regionalne samouprave prema socioekonomskoj razvijenosti, Društvena istraživanja: časopis za opća društvena pitanja, 23(2), str. 211-231.
16. Pivac, S. (2010): Statističke metode. Ekonomski fakultet u Splitu, Split.
17. Pivac S., Šego B. (2006): Statistika, Alka Script, Zagreb.
18. Poston, D., Bouvier L. (2010): Population & Society: An Introduction to Demography, Cambridge University Press.

19. Puljiz, V. (2005): Demografski trendovi u Europi, Revija za socijalnu politiku, 12(2), str. 263-271.
20. Puljiz, V. (2016): Starenje stanovništva–izazov socijalne politike. Revija za socijalnu politiku, 23(1), str. 81-98.
21. Rašić Bakarić, I. (2006): Primjena faktorske i klaster analize u otkrivanju regionalnih nejednakosti, Privredna kretanja i ekonomska politika, 15(105), str. 52-76.
22. Romesburg, C. (2004): Cluster analysis for researchers, Lulu Press, North Carolina.
23. Rozga, A., i Grčić, B. (2009): Poslovna statistika, Ekonomski fakultet u Splitu, Split.
24. Rozga, A. (2009): Statistika za ekonomiste, Ekonomski fakultet u Splitu, Split.
25. Rowland, D. (2003): Demographic Methods and Concepts, Oxford University Press.
26. Stropnik, N. (1995): Ciljevi, mjere i posljedice populacijske i obiteljske politike, Revija za socijalnu politiku, 2(3), str. 215-222.
27. Swanson, D; Siegel, J.: The Methods and Materials of Demography, Elsevier.
28. Šošić, I. (2004): Primijenjena statistika, Školska knjiga, Zagreb.
29. Tadić, J., Dragović, F., Tadić, T. (2016): Migracijska i izbjeglička kriza–sigurnosni rizici za EU, Policija i sigurnost, 25(1/2016), str. 14-42.
30. Tcholakov, N. (2005): Mortalitet i očekivano trajanje života u zemljama koje su pristupile Europskoj uniji - dugoročni izgledi, Migracijske i etničke teme, 21(1-2), str.91-109.
31. Zelenika, R. (2000): Metodologija i tehnologija izrade znanstvenog i stručnog djela, 4. izdanje, Ekonomski fakultet u Rijeci, Rijeka.
32. Weeks, J.R. (2011): Population: An Introduction to Concepts and Issues, Wadsworth Publishing.
33. Wertheimer-Baletić, A. (1982): Demografija stanovništvo i ekonomski razvitak, Informator, Zagreb.
34. Wertheimer-Baletić, A. (2005): Populacijska politika u razvijenim europskim zemljama, Rad Hrvatske akademije znanosti i umjetnosti, str. 297-330.
35. Wertheimer-Baletić, A. (1999): Stanovništvo i razvoj, Mate, Zagreb.

Ostali izvori:

1. Europe Direct Čakovec, https://edic-cakovec.eu/stanovnistvo-eu-a-u-2016-broji-vise-od-510-milijuna-stanovnika/
2. Eurostat, http://ec.europa.eu/eurostat

3. Metode znanstvenih istraživanja, http://www.unizd.hr/portals/4/nastavni_mat/1_godina/metodologija/METODE_ZNANSTVENIH_ISTRAZIVANJA.pdf
4. Ministarstvo vanjskih i europskih poslova RH, http://www.mvep.hr/hr/
5. Poslovni dnevnik, Demografska slika Europe, http://www.poslovni.hr/tag/demografska-slika-europe-2414
6. Službene web-stranice Europske unije, https://europa.eu/european-union/index_hr

POPIS SLIKA

Slika 1: Zemlje članice Europske unije ……. 13
Slika 2. Klasifikacija zemalja EU-28 u 15 klastera prema demografskim značajkama u 2015. godini pomoću dendograma ……. 34
Slika 3. Klasifikacija zemalja EU-28 u 9 klastera prema 9 demografskih značajki u 2015. godini pomoću dendograma ……. 52
Slika 4. Klasifikacija zemalja EU-28 u 9 klastera prema 5 demografskih značajki u 2015. godini pomoću dendograma ……..…….. 54

POPIS TABLICA

Tablica 1. Klasifikacija zemalja EU-28 prema demografskim značajkama u 2015. godini u 2 do 15 klastera pomoću hijerarhijske metode ……...… 35

Tablica 2. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 14 klastera pomoću metode k-prosjeka ……...……...… 37

Tablica 3. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 14 klastera pomoću metode k-prosjeka ……..……...… 38

Tablica 4. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 13 klastera pomoću metode k-prosjeka …….…..……...… 39

Tablica 5. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 13 klastera pomoću metode k-prosjeka ……..…..… 40

Tablica 6. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 12 klastera pomoću metode k-prosjeka …….…..……...… 41

Tablica 7. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 12 klastera pomoću metode k-prosjeka ……..……...… 42

Tablica 8. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 11 klastera pomoću metode k-prosjeka …….……..……...… 43

Tablica 9. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 11 klastera pomoću metode k-prosjeka ……..……...… 44

Tablica 10. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 10 klastera pomoću metode k-prosjeka …….……..……...… 45

Tablica 11. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 10 klastera pomoću metode k-prosjeka ……...……..……...… 46

Tablica 12. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 8 klastera pomoću metode k-prosjeka …….……...… 47

Tablica 13. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 8 klastera pomoću metode k-prosjek …….....… 48

Tablica 14. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 6 klastera pomoću metode k-prosjek ……..……..... 49

Tablica 15. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 6 klastera pomoću metode k-prosjeka …… 50

Tablica 16. Klasifikacija zemalja EU-28 prema 9 demografskih značajki u 2015. godini 2 do 9 klastera pomoću hijerarhijske metode ……..… 53

Tablica 17. Klasifikacija zemalja EU-28 prema 5 demografskih značajki u 2015. godini 2 do 9 klastera pomoću hijerarhijske metode ……..… 55

Tablica 18. Klasifikacija 28 zemalja Europske unije na temelju 9 odabranih demografskih pokazatelja u 6 klastera pomoću metode k-prosjeka ……... 57

Tablica 19. Analiza varijance (ANOVA) na temelju 9 odabranih demografskih pokazatelja u 9 klastera pomoću metode k-prosjeka …… 58

Tablica 20. Klasifikacija 28 zemalja Europske unije na temelju 5 odabranih demografskih pokazatelja u 9 klastera pomoću metode k-prosjeka ……...… 59

Tablica 21. BDP po stanovniku u svakoj zemlji članici EU-28 u 2015. godini …… 60

Tablica 22. Analiza varijance (ANOVA) na temelju 5 odabranih demografskih pokazatelja u 9 klastera pomoću metode k-prosjeka ……..... 61

Tablica 23. Broj osoba koje su zatražile azil u zemljama EU-28, a dolaze iz zemalja izvan EU-28 u 2015. godini ……...…….. 62

SAŽETAK

Demografske značajke poput opadanja fertiliteta, starenja stanovništva, migracija, transformacija strukture i funkcija obitelji najvažniji su demografski problemi s kojima se susreće Europska unija, a utječu na gospodarske i socijalne probleme, a samim time i na način provođenja aktivne demografske politike.

Kako bi ostvarili glavi cilj ovog rada, grupiranje članica Europske unije u homogene grupe (klastere) s obzirom na njihova demografska obilježja, provedena je multivarijacijska Cluster analiza. Provedenom analizom ustanovljeno je da se optimalno rješenje javlja kod klasificiranja u 9 klastera, jer dolazi do pojave stabilnih rezultata bez obzira na smanjenje broja kriterija klasificiranja.

Također, zaključuje se da čak 15 od 28 zemalja članica Europske unije tvori jedan klaster, a Njemačka, Francuska, Italija, Luksemburg i Velika Britanija tvore zasebne klastere. Ovih 5 zemalja ujedno su i zemlje u kojima je zatražen najveći broj azila, a većina tih zemalja ubraja se i među osnivačice Europske unije. Isto tako, sve zemalje koje su se istaknule s visokim BDP-om po stanovniku, nisu se izdvojile kao zasebne.

Ključne riječi: Europska unija, demografski pokazatelji, Cluster analiza

SUMMARY

Demographic features such as decline in fertility, aging of the population, migration, transformation of the structure and function of the family are the most important demographic problems in the European Union, affecting economic and social problems, and thus in the way of active demographic policy.

In order to achieve the goal of this paper, the grouping of EU members into homogeneous groups (clusters) with regard to their demographic characteristics, multivariate Cluster analysis was carried out. The analysis showed that the optimal solution occurs during the classifying in the 9 clusters, because of stable results despite the number of classification criteria being reduced.

It is also concluded that 15 of the 28 member states of the European Union form one cluster, and Germany, France, Italy, Luxembourg and United Kingdom form separate clusters. These five countries are also the countries with the largest number of asylum applications, and most of these countries are founding members of the European Union. In addition to that, all countries that have high GDP per capita are not classified as separate.

Key words: European Union, demographic indicators, Cluster analysis