GOSPODARSKE RAZLIKE ŢUPANIJA RH-VIŠEKRITERIJALNA ANALIZA

Topić, Josipa-Magda

Master's thesis / Diplomski rad

2018

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:124:393623

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

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

DIPLOMSKI RAD

GOSPODARSKE RAZLIKE ŽUPANIJA RH-VIŠEKRITERIJALNA ANALIZA

MENTOR:

Prof. dr. sc. Zoran Babić

STUDENTICA:

Josipa-Magda Topić

Broj indeksa: 2162350

Split, srpanj 2018.

SADRŽAJ:

1.UVOD 4

1.1. Problem i predmet istraživanja 4

1.2. Ciljevi i doprinos istraživanja 7

1.3. Metode istraživanja 7

1.4. Struktura diplomskog rada 8

2. OPIS ALTERNATIVA (ŽUPANIJA) I KRITERIJA 9

2. 1. Regionalna podjela Republike Hrvatske 9

2.2. Općenito o županijama 11

2.3. Kriteriji 19

2.3.1. Indikatori obrazovanja 20

2.3.2. Ekonomski indikatori 21

2.3.3. Indikatori infrastrukture 29

3. VIŠEKRITERIJALNO ODLUČIVANJE 30

3.1. Pojam i karakteristike višekriterijalnog odlučivanja 30

3.2. Formiranje matrice odluke 32

3. 3. Procjena važnosti kriterija 34

3.3.1. Metoda svojstvenog vektora 34

3.3.1.1. Procjena važnosti kriterija aproksimativnim postupkom……36

3.3.1.2. Expert Choice……37

4. PRIMJENA PROMETHEE METODE 43

4.1. PROMETHEE metoda 43

4.2. Ulazni i izlazni tok 49

4.3. Ulazni podaci za PROMETHEE metodu 51

4.3.1. Popis generaliziranih kriterija i pripadajućih parametara 51

4.4. Rezultati istraživanja 55

4.4.1.PROMETHEE I 55

4.4.2. PROMETHEE II 56

ZAKLJUČAK 60

LITERATURA 61

POPIS TABLICA **63**
POPIS SLIKA **64**
SAŽETAK **65**
SUMMARY **65**

1.UVOD

1.1. Problem i predmet istraživanja

Republika Hrvatska, čija kopnena površina iznosi 56.594 km^2, administrativno je podijeljena na 20 županija i Grad Zagreb koji ima status županije. Uspostava sustava lokalne samouprave u Republici Hrvatskoj započela je 1992. godine postavljanjem zakonodavnog okvira. Sustav je uspostavljen 1993. godine stupanjem na snagu zakona kojima se uređuje teritorijalni ustroj, samoupravni djelokrug, izborni sustav i način financiranja lokalne samouprave, a oživotvoren je provedbom prvih lokalnih izbora.

Jedinice lokalne samouprave jesu općine i gradovi, a jedinice područne samouprave su županije. U Republici Hrvatskoj ustrojeno je ukupno 555 jedinica lokalne samouprave i to su: 428 općina, 127 gradova te 20 jedinica područne samouprave, odnosno županija. Kao glavni grad Republike Hrvatske Grad Zagreb ima poseban status grada i županije, tako da je u Republici Hrvatskoj ukupno 576 jedinica lokalne i područne samouprave.[1]

Iako se nalaze na relativnoj maloj površini, prema određenim pokazateljima postoje velike razlike između pojedinih županija što se u ovom radu želi detaljnije istražiti pomoću metoda višekriterijalnog odlučivanja.

Svaka od županija ima utjecaj na gospodarski rast i razvoj države u cjelini. Po svom teritorijalnom položaju kao i ekonomskoj strukturi gospodarstva svaka županija je specifična te su ekonomski pokazatelji uspješnosti po županijama vrlo različiti. Županijske razlike su iznimno povećane u zadnjih nekoliko godina, a samim time je ova tema aktualna i kao takva odabrana za provedbu istraživanja. Osnovna namjena ovog rada je istražiti, izvršiti usporedbu, te rangirati županije od najbolje do najlošije na temelju više kriterija.[2] Konkretan primjer temelji se na 14 pokazatelja grupiranih u 3 karakteristične skupine. Analiza se provodi za ukupno 21 županiju.[3]

Analizirano razdoblje obuhvaća podatke iz 2015. godine jer se veliki broj pokazatelja temelji na podacima dostupnim za navedenu godinu.

[1] Hgk.hr : Zupanije- velike gospodarske razlike na malom prostoru- https://www.hgk.hr/documents/upanijevelikegospodarskerazlikenamalomprostoru

[2] Babić, Z.(2011): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split.

[3] Z.Babić, B.Grčić: "Evaluation of relative Development Level for Croatian Counties", Zbornik radova KOI '98, Rovinj, 1998, p. 39-48.

Prilikom izrade koriste se podaci o županijama i Gradu Zagrebu preuzetih od nacionalnog vijeća za konkurentnost[4] i Hrvatske gospodarske komore.

Namjena rada je doći do spoznaje svih činjenica koja će dati jasnu sliku razlika koja se pojavljuju na spomenutim područjima. Konačno, predviđen je sljedeći skup indikatora za mjerenje razvoja:

1. INDIKATORI OBRAZOVANJA

- f1 - Viša škola u populaciji 25-64 god.
- f2 - Visoka škola u populaciji 25-64 god.
- f3 - Upisani studenti u razdoblju 20-24 god.
- f4 - Diplomirani studenti u razdoblju 20-24 god.

2. EKONOMSKI INDIKATORI

- f5 – BDP po stanovniku
- f6 – Ukupno nezaposleni u RH
- f7 – Ukupno zaposleni u RH
- f8 – Prosječna mjesečna neto plaća
- f9 – Poslovanje poduzetnika- prihod poduzetnika u mil. HRK
- f10 - Indeks gospodarske snage županija

3. INDIKATORI INFRASTRUKTURE

- f11 - Razvijenost opće infrastrukture
- f12 - Izgrađenost željezničke mreže
- f13 - Razvijenost lučkih objekata
- f14 - Kvaliteta i sigurnost opskrbe električnom energijom

[4] Konkurentnost.hr :Regionalni indeks konkurentnosti Hrvatske 2013- http://konkurentnost.hr/wp-content/uploads/2018/01/RIK2013_finalno_07072014.pdf

Skup alternativa koje je potrebno rangirati na temelju prethodno navedenih indikatora čini 21 županija Hrvatske, točnije:

1. Zagrebačka županija
2. Krapinsko-zagorska
3. Sisačko-moslavačka
4. Karlovačka
5. Varaždinska
6. Koprivničko-križevačka
7. Bjelovarsko-bilogorska
8. Primorsko-goranska
9. Ličko-senjska
10. Virovitičko-podravska
11. Požeško-slavonska
12. Brodsko-posavska
13. Zadarska
14. Osječko-baranjska
15. Šibensko-kninska
16. Vukovarsko-srijemska
17. Splitsko-dalmatinska
18. Istarska
19. Dubrovačko-neretvanska
20. Međimurska
21. Grad Zagreb

U istraživanju ćemo se koristiti PROMETHEE metodom te će se analizom prikupljenih podataka o županijama donijeti zaključak o razlikama na temelju dostupnih gospodarskih pokazatelja i navedenih kriterija. Izvršit će se rangiranje županija, te odabir najbolje alternative pomoću metode PROMETHEE. Iz definiranog predmeta istraživanja postavlja se sljedeća hipoteza :

H1: VIŠEKRITERIJALNOM ANALIZOM MOGUĆE JE NAPRAVITI USPOREDBU RAZVIJENOSTI ŽUPANIJA.

1.2. Ciljevi i doprinos istraživanja

Ciljevi ovog rada su kvalitetno sagledati dostupne podatke županija, usporediti njihove statuse na temelju gospodarskih pokazatelja, rangirati ih, te donijeti odluku koja je najbolja a koja najlošija alternativa. Rad će se sastojati od teorijskog dijela gdje će se definirati razlike između županija, opis same PROMETHEE metode i opis programskog paketa Decision Lab koji se koristi za rješavanje PROMETHEE metode. Također će se opisati i koraci metode svojstvenog vektora pomoću koje odlučujemo o važnosti kriterija. Nakon toga slijedi empirijski dio gdje će se pomoću istraživanja preko PROMETHEE metode doći do procjene rangova županija.

Dobiveni rezultati u istraživanju će pomoći da se utvrde županijske razlike, prikazat će se rješavanje problematike višekriterijalnih problema koji nastaju u slučajevima većeg broja kriterija. Pojava višekriterijalnih problema sve je češća u poslovnom svijetu, stoga poznavanje metoda postaje od iznimne važnosti. PROMETHEE metoda uz dovoljne informacije o županijama, te pravilno definirane indikatore uz pomoć programskog paketa Decision Lab omogućit će izbor najbolje alternative iz prethodno definiranog skupa alternativa.

1.3. Metode istraživanja

U teorijskom dijelu istraživanja koristit će se opće znanstvene metode [5]:

- metoda analize - raščlanjivanje složenih pojmova, sudova, zaključaka na njihove jednostavnije dijelove, te izučavanje svakog dijela za sebe.
- metoda sinteze - povezivanje jednostavnijih pojmova, sudova i zaključaka u složene.
- metoda deskripcije - jednostavno opisivanje činjenica i procesa te njihovih empirijskih potvrđivanja odnosa i veza.
- statističke metode – prikupljanje podataka i informacija, grafičko i tabelarno prikazivanje, donošenje zaključaka, tumačenje rezultata.
- metoda kompilacije – preuzimanje tuđih opažanja, stavova, zaključaka i spoznaja.

U praktičnom dijelu rada koristit će se metoda za višeatributivno odlučivanje PROMETHEE te metoda za procjenu važnosti kriterija, točnije, metoda svojstvenog vektora.

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

1.4. Struktura diplomskog rada

Rad je strukturiran u 6 poglavlja, a svako od njih u uži broj cjelina. Nakon uvodnog dijela, drugi i treći dio su teoretski aspekt istraživanja, četvrti dio je empirijski te posljednji dio zaključak.

U uvodnom dijelu definiran je predmet koji se želi istražiti, cilj koji se želi postići, znanstvene metode koje će se koristiti u teorijskom i empirijskom dijelu, te struktura rada.

Drugi dio rada odnosi se na županijsku podjelu RH te se daje pregled osnovnih pojmova. Navode se 3 skupine kriterija sa svojim sastavnicama koje se koriste u ovom istraživanju. Analizira se razvijenost pojedine županije te se vrše usporedbe istih na temelju gospodarskih pokazatelja.

Treći dio rada odnosi se na područje višekriterijalnog odlučivanja te je posebna pažnja posvećena metodi PROMETHEE, izuzetno popularnoj metodi poslovnog odlučivanja koja je veoma široko korištena u nizu problema poslovnog odlučivanja. Posebno je analizirana metoda svojstvenog vektora, metoda koja je posvećena problemima ocjene važnosti pojedinih kriterija.

Nakon pojmovnog određenja i definiranja ciljeva u četvrtom dijelu definiraju se koraci provedbe istraživanja te se grafički prikazuju postupci korištene metode PROMETHEE. U njemu će se prikazati detaljno rangiranje pomoću navedene metode.

Peti dio donosi zaključak rezultata.

Na kraju rada se daje popis korištene literature, popis slika i tablica, te sažetak.

2. OPIS ALTERNATIVA (ŽUPANIJA) I KRITERIJA

2.1. Regionalna podjela Republike Hrvatske

Regija[6] je dio zemljišne površine koju karakteriziraju određena obilježja (fizička, ekonomska, politička, itd.) koja ju čine jedinstvenim i različitim od drugih područja. Osnovu teritorijalno administrativne podjele u Europskoj uniji čine tzv. *NUTS* regije (franc. *Nomenclature des unites territoriales statistiques* - „Nomenklatura prostornih jedinica za statistiku"). NUTS je hijerarhijski sustav za identifikaciju i klasifikaciju prostornih jedinica za potrebe službene statistike u zemljama članica EU-a. Ove teritorijalne jedinice su definirane uglavnom zbog statističkih razloga pa zato nisu nužno i službene administrativno – teritorijalne jedinice. Međutim, one su iznimno važne obzirom na strukturu i mogućnost korištenja sredstava iz različitih fondova EU.

Za definiranje regija različite razine, koriste se različiti kriteriji ali je dominantan kriterij broja stanovnika, i to: (a) NUTS 1: 3-7 milijuna stanovnika, (b) NUTS 2: 800.000-3.000.000 stanovnika i (c) NUTS 3: 150.000-800.000 stanovnika.

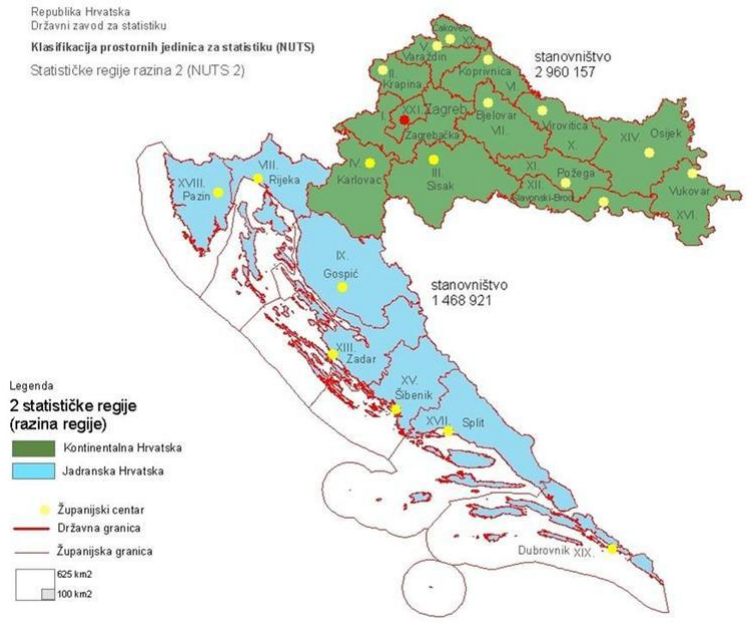
U RH se za potrebe klasifikacije na NUTS 2 razini od 01. siječnja, 2013. godine koristi nova podjela na dvije statističke regije: Kontinentalna Hrvatska i Jadranska Hrvatska koja je usuglašena s Eurostat-om, odnosno Europskom komisijom .

[6] Čavrak, V.(2003): Regionalni razvoj i regionalna politika Hrvatske, Hrvatski gospodarski razvoj, Ekonomski fakultet Zagreb i Politička kultura, Zagreb, str. 3.

HR01: Kontinentalna Hrvatska koju čine: Grad Zagreb, Zagrebačka, Krapinsko-zagorska, Varaždinska, Koprivničko-križevačka, Međimurska županija, Bjelovarsko-bilogorska, Virovitičko-podravska, Požeško-slavonska, Brodsko-posavska, Osječko-baranjska, Vukovarsko-srijemska, Sisačko-moslavačka i Karlovačka županija.

HR02: Jadranska Hrvatska koju čine: Primorsko-goranska, Ličko-senjska, Zadarska, Šibensko-kninska, Splitsko-dalmatinska, Istarska, i Dubrovačko-neretvanska županija.

Realiziran cilj Programa Vlade RH je dogovor s EU o novom preustroju statističkih regija u RH na ravnomjeran i brz regionalni razvoj na temelju korištenja fondova EU.[7]



Slika 1 : Nova statistička klasifikacija prostornih jedinica RH- NUTS 2
Izvor: www.mrrfeu.hr

[7] www.mrrfeu.hr

2.2. Općenito o županijama

Kako bi se prepoznali potencijali županija, djelatnosti s komparativnim prednostima te prirodna bogatstva općenito, u ovom poglavlju za svaku pojedinu županiju istaknuti su potencijali koji doprinose gospodarskoj snazi. [8]

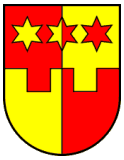


GRAD ZAGREB – Osnove gospodarskoga razvoja Grada Zagreba čine klasične i suvremene uslužne djelatnosti te industrija zasnovana na kombinaciji tehnološki složenijih proizvodnji s većom dodanom vrijednosti odnosno s izvozno konkurentnim proizvodima. Zagrebačko gospodarstvo ostvaruje oko 40% ukupnoga hrvatskog izvoza, najvećim dijelom na tržište EU. Grad Zagreb, sa statusom županije i specifičnostima glavnoga grada RH, daljnji razvoj temelji na postizanju optimalnog odnosa između proizvodnog i uslužnog sektora, posebice prerađivačke industrije, trgovine, turizma i financijskih usluga.[9]



ZAGREBAČKA ŽUPANIJA – Osnove gospodarskoga razvoja Zagrebačke županije čine poljoprivreda, industrija i klasične uslužne djelatnosti. Prirodne ljepote Županije i blizina glavnoga grada predispozicija su razvoja seoskog, lovnog, i ribolovnog turizma. Prirodna bogatstva, postojeći gospodarski kapaciteti, njihova modernizacija i izgradnja novih, rezultiraju kvalitetnim proizvodima plasiranima i na inozemna tržišta, pri čemu je pokrivenost uvoza izvozom 58%, pa je razvojni naglasak stavljen na jačanje izvozno orijentirane proizvodnje. Daljnji se razvoj temelji na poljoprivredi, prerađivačkoj posebice prehrambenoj industriji, transportnim i logističkim uslugama te bržem aktiviranju poduzetničkih zona.[10]

[8] https://www.hgk.hr/documents/upanijevelikegospodarskerazlikenamalomprostoru
[9] www.hgk.hr
[10] www.hgk.hr



KRAPINSKO-ZAGORSKA ŽUPANIJA – Blizina Zagreba, kvalitetna infrastruktura, konkurentna radna snaga i mogućnost ulaganja čine Krapinsko-zagorsku županiju idealnim mjestom za razvijanje gospodarske djelatnosti. Prerađivačka industrija temeljna je grana gospodarstva, a izvozno orijentirani proizvodi na zahtjevna strana tržišta pokazatelj su uspješnosti gdje zagorski poduzetnici ostvaruju trećinu ukupnih prihoda. Posljednjih godina mnogo se ulaže u razne oblike turizma koji karakteriziraju značajni prirodni i kulturno-povijesni resursi, očuvan okoliš, tradicija i gastro-enološka ponuda.[11]

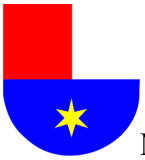


VARAŽDINSKA ŽUPANIJA – Temelj razvoja Varaždinske županije jest prerađivačka industrija s velikim potencijalom rasta izvoza, koju čine međunarodno-konkurentne tvrtke, uspješni MSP te brojni strani ulagači koji su prepoznali uspješnost "varaždinskog recepta". Zato je Varaždinska županija još 2010. proglašena najkonkurentnijom županijom u RH. Od 2000. izvoz je povećan 350% i iznosi 8,2% ukupnoga hrvatskog izvoza, što županiju čini "najizvoznijom" županijom koja ostvaruje najveći suficit.[12]



KOPRIVNIČKO-KRIŽEVAČKA ŽUPANIJA – Osnove gospodarskog razvoja Koprivničko-križevačke županije čine prerađivačka industrija, osobito prehrambena i farmaceutska (s nekoliko jakih lidera), trgovina, poljoprivreda i građevinarstvo. Gospodarstvo, najvećim dijelom prerađivačka industrija, izvozi svoje proizvode i usluge te ostvaruje pozitivan saldo vanjskotrgovinske razmjene. Postoje kvalitetni turistički potencijali za razvoj kulturnog turizma (kolijevka naivne umjetnosti, bogata kulturno-povijesna baština, tradicijske manifestacije), seoskog i wellness turizma, te raznih oblika kontinentalnog turizma.[13]

[11] www.hgk.hr
[12] www.hgk.hr
[13] www.hgk.hr



MEĐIMURSKA ŽUPANIJA – Gospodarstvo Međimurske županije pretežno je tradicionalno, radno intenzivno i izvozno orijentirano. Županiju karakterizira razvijeno malo i srednje poduzetništvo, sve jači razvoj autohtonih i tradicijskih proizvoda te vrlo povoljni geografski položaj na sjecištu važnih europskih koridora. Konkurentnosti doprinose kvaliteta poslovnog okruženja, brojne poduzetničke zone i suradnja obrazovanja i gospodarstva. Županija je pretežno ruralno područje koje pruža odlične uvjete za poljoprivrednu proizvodnju, a naročito je razvijeno plantažno voćarstvo. Dobar geografski položaj, očuvan okoliš te prirodne ljepote predispozicija su za daljnji razvoj turizma.[14]



BJELOVARSKO-BILOGORSKA ŽUPANIJA – Županiju Bjelovarsko-bilogorsku čini poticajno gospodarsko okruženje temeljeno na tradiciji u poljoprivredi, obrtništvu i turizmu uz ostvariv visok stupanj dodane vrijednosti s očuvanim okolišem te prirodnom i kulturnom baštinom. Najveći prirodni potencijali i gospodarsko obilježje BBŽ jesu raspoloživa poljoprivredna tla i šume gdje se razvila proizvodnja hrane i drvoprerađivačka industrija u kojoj se i ostvaruje najveći udio u ukupnom županijskom izvozu. Vidljiva je tendencija rasta i povećanja površina zasađenih pod vinovom lozom u sklopu kojih se razvija ruralni turizam. Kraj je bogat obnovljivim izvorima energije, a geotermalna elektrana Velika Ciglena, koja će uskoro biti puštena u pogon, bit će najveća Europska ORC (Organski Rankineov Ciklus) geotermalna elektrana.[15]



VIROVITIČKO-PODRAVSKA ŽUPANIJA – Osnove gospodarskog razvoja Virovitičko-podravske županije čine poljoprivreda (proizvodnja šećerne repe, duhana i ljekovitog bilja) i industrija (drvno-prerađivačka, prehrambena, industrija nemetala). Prirodne ljepote županije predispozicija su razvoja turizma.

[14] www.hgk.hr
[15] www.hgk.hr

Prirodna bogatstva, modernizirani kapaciteti te izgradnja novih, rezultiraju kvalitetnim proizvodima, što uz poštivanje svih ugovornih obveza, omogućava županijskom gospodarstvu izvoz proizvoda na zahtjevno svjetsko tržište te u robnoj razmjeni sa 73 države redovito ostvaruje suficit koji je u 2014. godini iznosio 77,7 mil. USD.[16]



POŽEŠKO–SLAVONSKA ŽUPANIJA – Požeško-slavonska županija izvozno je orijentirana u segmentima prerađivačke industrije: drvne, metalske, prehrambene, proizvodnje stakla i električnih elemenata. Gospodarstvo PSŽ izvozi u više od 30 zemalja. Svoj potencijal Županija vidi u razvoju poljoprivrednih proizvoda (5500 OPG-ova), stavljanju svojih prirodnih potencijala u gospodarsku funkciju (voda 2% površine, termalni izvori, obradivo zemljište 43%, šume 45%), razvoju turizma kroz netaknutu i nezagađenu prirodu (Park prirode Papuk), kulturnu baštinu, životinjski i biljni svijet te kao već poznatu vinsku destinaciju.[17]



BRODSKO-POSAVSKA ŽUPANIJA – Osnove gospodarskog razvoja Brodsko-posavske županije čine prerađivačka industrija (izvozno orijentirane: metalna, drvna, prehrambena i proizvodnja namještaja), poljoprivreda, građevinarstvo, trgovina i uslužne djelatnosti. Povoljan geostrateški položaj (raskrižje X i Vc prometnog koridora), prometna infrastruktura (ceste, željeznica, plovni put), prirodna bogatstva, kulturno-povijesno naslijeđe i spremnost obrazovnog sustava i akademske zajednice da se prilagodi potrebama gospodarstva, pružaju preduvjete za intenzivniji razvoj gospodarstva i ostalih djelatnosti koje utječu na razvoj županije.[18]



OSJEČKO-BARANJSKA ŽUPANIJA – Osnove gospodarskog razvoja Osječko-baranjske županije čine poljoprivreda i industrija, čiji kapaciteti nisu dovoljno iskorišteni zbog usitnjenosti poljoprivrednih površina, niske razine tehnološke opremljenosti i nedovoljnih inozemnih i domaćih ulaganja.

[16] www.hgk.hr
[17] www.hgk.hr
[18] www.hgk.hr

Prirodne ljepote županije pridonose razvoju ruralnog turizma. Očuvani i bogati prirodni resursi, postojeći gospodarski kapaciteti i njihova modernizacija uz povoljan prometno-geografski položaj rezultiraju tradicionalnom izvoznom orijentacijom, a županijsko gospodarstvo u robnoj razmjeni sa stotinjak zemalja već niz godina redovito ostvaruje suficit. Razvoj IT industrije i usmjerenost proizvodnji energije iz obnovljivih izvora zauzimaju sve važnije mjesto u gospodarstvu županije.[19]



VUKOVARSKO-SRIJEMSKA ŽUPANIJA – Osnovu gospodarskog razvoja Vukovarsko-srijemske županije čine prirodni resursi (poljoprivredno zemljište, šumsko bogatstvo, vode) na temelju kojih je razvijena primarna poljoprivredna proizvodnja te prerađivačka industrija u kojoj su dominantne prehrambena i drvoprerađivačka industrija. U strukturi gospodarskih djelatnosti, pored ranije nabrojenih, zastupljene su i kožarsko-tekstilna te metaloprerađivačka industrija. Lokacija, te postojeći željeznički i plovni putevi, značajni su potencijal na osnovu kojih se radi na pozicioniranju županije kao značajnoga transportno-logističkog centra u budućnosti, a uz postojeće prirodne ljepote i kulturno-povijesno nasljeđe također omogućuju i značajniji razvoj kontinentalnog turizma koji je zasad u povojima.[20]



KARLOVAČKA ŽUPANIJA – Karlovačka županija nalazi se u središnjoj Hrvatskoj, veza je kontinentalne i obalne Hrvatske te sjecište najvažnijih prometnica koje povezuju Europu s Jadranskom obalom. Gospodarsku sliku karakterizira razvijeno poduzetništvo u kojemu je glavni nositelj razvoja prerađivačka industrija s djelatnostima proizvodnje hrane i pića, gotovih metalnih proizvoda, strojeva i uređaja, proizvoda od gume i plastike, prerade drva i proizvodnje tekstila. Važno mjesto zauzimaju trgovina i graditeljstvo, uz značajne kulturne i prirodne resurse za razvoj turizma. U strukturi izvoza Županije prevladavaju proizvodnja metalnih proizvoda i proizvodnja strojeva i uređaja, dok su glavna izvozna tržišta EU i SAD.[21]

[19] www.hgk.hr
[20] www.hgk.hr
[21] www.hgk.hr



SISAČKO-MOSLAVAČKA ŽUPANIJA – Sisačko-moslavačka županija jest proizvodno-izvozna županija, a najjače su grane energetika, naftna, petrokemijska, metaloprerađivačka, drvna i prehrambena industrija. Prisutan je razvoj sofisticiranih tehnologija u elektroničkoj i farmaceutskoj industriji dok su ostale gospodarske grane i obrtništvo manje zastupljeni. Poljoprivredni potencijali nisu dovoljno iskorišteni, a turističku ponudu, uz sačuvane kulturno-povijesne vrijednosti, čine Park prirode Lonjsko polje, termalno lječilište Topusko, Vinske ceste Moslavine. Izvoz je u 2015. iznosio 529,4 mil. EUR, od toga najviše prema zemljama EU.[22]



PRIMORSKO-GORANSKA ŽUPANIJA – Primorsko-goranska županija s 296.195 stanovnika, obuhvaća 3.582 km² kopnene i 4.344 km² morske površine. Ima najveće otoke Krk, Lošinj, Rab i Cres te najveće bogatstvo flore i faune u Hrvatskoj. Grad Rijeka najvažnija je hrvatska morska luka i važan sveučilišni, poslovni i kulturni centar. Uz lučku i pomorsko-prometnu infrastrukturu, dominiraju brodogradnja, metaloprerađivačka djelatnost, farmacija te prijevoz i prerada nafte. Prerađivačka industrija, građevinarstvo, trgovina, prijevoz, turizam i znanstveno-tehničke djelatnosti ostvaruju 87% ukupnih prihoda te glavninu županijskog izvoza.[23]



LIČKO-SENJSKA ŽUPANIJA – Gospodarsku snagu Ličko-senjske županije čine turizam, poljoprivreda i drvna industrija. Prirodne ljepote Županije predispozicija su razvoja turizma: seoskog, lovnog i ribolovnog. Prirodna bogatstva, postojeći gospodarski kapaciteti i njihova modernizacija te izgradnja novih, rezultiraju kvalitetnim proizvodima, što, uz poštivanje ugovorenih rokova isporuke i ispunjavanje ostalih ugovornih obveza, omogućava da županijsko gospodarstvo izvozi svoje proizvode na zahtjevno svjetsko tržište te u robnoj razmjeni, sa 79 zemalja, redovito ostvaruje suficit.[24]

[22] www.hgk.hr
[23] www.hgk.hr
[24] www.hgk.hr



ZADARSKA ŽUPANIJA – Gospodarski razvoj Zadarske županije najviše potiču turizam, prerađivačka industrija, ribarstvo, marikultura i brodarstvo. Dobar prirodni položaj i ulaganja u prometnu infrastrukturu, pridonijeli su razvoju turizma i djelatnosti koje ga prate. Razvoj je također povezan s preradom sirovina iz mora namijenjenih uglavnom tržištu EU i Japana. Prerađivačka industrija ima dugu tradiciju koja proizvode i usluge plasira za potrebe auto, prehrambene i farmaceutske industrije Europske unije te, uz prehrambenu industriju, čini glavninu industrije Zadarske županije. Značajni izvoz usluga ostvaruje se i u brodarstvu. Županijsko gospodarstvo ostvaruje vanjskotrgovinski suficit. Prema demografskim procjenama Ekonomskog fakulteta u Zagrebu, među svim županijama jedino Zadarska županija, uz Grad Zagreb, 2030. godine trebala bi imati više stanovnika nego u 2013. Godini.[25]



ŠIBENSKO-KNINSKA ŽUPANIJA – Osnove gospodarskog razvoja Šibensko-kninske županije čine prerađivačka industrija, turizam i trgovina. Nakon višegodišnjih problema u preradi aluminija, proizvodnja je opet pokrenuta te se vraća optimizam da će 80 godina duga tradicija u aluminijskoj industriji ponovo biti pokretač gospodarstva županije. Sve veće značenje za gospodarstvo ima turizam s godišnjim ostvarenjima 5 milijuna noćenja i 822.000 turista. Prepoznatljivost turističke ponude temelji se na prirodnim ljepotama, razvedenom i atraktivnom akvatoriju, bogatom kulturno-povijesnom nasljeđu te očuvanim tradicijskim djelatnostima.[26]



SPLITSKO-DALMATINSKA ŽUPANIJA – Splitsko-dalmatinska županija, uz turizam koji unatoč sezonalnosti, bilježi sve bolje rezultate, snažan potencijal za gospodarski uzlet ima u nekad moćnoj prerađivačkoj industriji koju je, uz povećanje ulaganja i oslanjanje na postojeći visoko obrazovani kadar, moguće obnoviti te povećati broj tvrtki koje uspješno posluju i izvoze.

[25] www.hgk.hr
[26] www.hgk.hr

Mogućnosti za razvoj i investicije brojne su s obzirom na izniman potencijal – izvanredna prirodna i klimatska osnovica, tradicija u pomorstvu, ribarstvu, maslinarstvu, vinogradarstvu, voćarstvu, vađenju i obradi kamena te graditeljstvu, prilike su za promjenu trenda depopulacije ruralnih područja i neravnomjernog razvoja županije.[27]



ISTARSKA ŽUPANIJA – Gospodarstvo Istarske županije temelji se na industriji i turizmu. Nasljednici stoljetne tradicije u brodogradnji, metaloprerađivačkoj i duhanskoj industriji te proizvodnji građevinskog materijala i cementa i danas uspješno posluju na svjetskom tržištu, a brojne druge tvrtke zahvaljujući modernim tehnologijama svoje proizvode plasiraju u izvoz. Visoko razvijeni turizam nudi kvalitetne smještajne i ugostiteljske kapacitete uz more i u unutrašnjosti poluotoka, a kao poseban doživljaj nudi vrhunske proizvode lokalne poljoprivrede, osobito maslinarstva, vinarstva i ribarstva te bogatu kulturno-povijesnu baštinu. Kvalitetan uslužni sektor zaokružuje sliku uspješnog istarskoga gospodarstva.[28]



DUBROVAČKO-NERETVANSKA ŽUPANIJA – Bogato kulturno povijesno nasljeđe i prirodne ljepote Dubrovačko-neretvanske županije osnova su razvoja turizma kao glavne gospodarske djelatnosti s udjelom više od 60% u ukupnim prihodima županijskoga gospodarstva. Vrlo vrijedna poljoprivredna područja nalaze se u dolini Neretve (najznačajniji proizvođač mandarina u državi), Konavoskom polju, Pelješcu i Korčuli (proizvodnja poznatih vina Dingač, Pošip, Postup i Malvazija). Daljnji razvoj gospodarstva naslanjat će se na selektivne oblika turizma; podizanje vinograda, maslinika, voćnjaka i povrtnjaka; razvoj ribarstva.[29]

[27] www.hgk.hr
[28] www.hgk.hr
[29] www.hgk.hr

2.3. Kriteriji

Kriteriji korišteni u ovom radu preuzeti su sa službenih web stranica Hrvatske gospodarske komore i Nacionalnog vijeća za konkurentnost. Osim što su podijeljeni u 3 skupine, podijeljeni su na statističke, perceptivne, i pokazatelje službenih podataka na razini županija. Prosječne vrijednosti statističkih rangova za Hrvatsku po stupovima konkurentnosti izračunate su kao ponderirani prosjek županijskih rangova po čemu se kriterij udjela stanovništva županije u ukupnom stanovništvu Hrvatske koristi kao ponder. U ovu skupinu pripadaju indikatori obrazovanja.

Prosječne vrijednosti ocjena za perceptivne stupove konkurentnosti za Hrvatsku izračunate su kao ponderirani prosjek ocjena po županijama, pri čemu se kriterij udjela stanovništva županije u ukupnom stanovništvu Hrvatske koristi kao ponder. U ovu skupinu pripadaju indikatori infrastrukture. Analiza kvalitativnih podataka dobivena je istraživanjem mišljenja gospodarstvenika radi prikupljanja podataka koji nisu dostupni statističkim putem, odnosno nisu izravno mjerljivi putem statističkih pokazatelja. Anketa je dobivena prema metodologiji istraživanja koju koristi Svjetski gospodarski forum te je većina anketnih pitanja jednaka pitanjima ankete koja se koristi za izračun konkurentnosti zemalja u Globalnom izvješću o konkurentnosti. Originalni upitnik je modificiran kako bi odgovarao logici istraživanja na razini županija a ne nacionalnog gospodarstva. Svaki indikator iz kojeg se gradi perceptivni stup konkurentnosti ocjenjivan je ocjenama od 1 do 7, pri čemu je ocjena 1 najslabija, a 7 najbolja.[30]

U skupini ekonomskih pokazatelja korišteni su posljednji službeni podaci na razini županija iz 2015. godine preuzetih sa službenih stranica Hrvatske gospodarske komore.

[30] http://konkurentnost.hr/wp-content/uploads/2018/01/RIK2013_finalno_07072014.pdf

2.3.1. Indikatori obrazovanja

- **Viša škola u populaciji 25-64 godine** – pripada skupini indikatora obrazovanja, kao statistički pokazatelj prikazuje postotak udjela osoba sa višom školom u populaciji od 25 do 64. godine života. Vrijednost je donesena kao rezultat popisa stanovništva koji se objavljuje svakih 10 godina. Točnije, za podatke korištene u ovom radu, primijenio se popis stanovništva iz 2011. godine. Viša škola obuhvaća stanovništvo sa završenim stručnim studijem, i preddiplomski.

- **Visoka škola u populaciji 25-64 godine** - pripada skupini indikatora obrazovanja, kao statistički pokazatelj prikazuje postotak udjela osoba sa visokom školom u populaciji od 25 do 64. godine života. Visoka škola obuhvaća stanovništvo sa završenim diplomskim studijem. Vrijednost je donesena kao rezultat popisa stanovništva koji se objavljuje svakih 10 godina. Točnije, za podatke korištene u ovom radu, primijenio se popis stanovništva iz 2011. godine.

- **Upisani studenti u razdoblju 20-24 godine** - pripada skupini indikatora obrazovanja, kao statistički pokazatelj prikazuje postotak upisanih studenata dobiven omjerom upisanih studenata prema popisu stanovništva 2011. godine, te stanovništvom u dobi od 20-24. godine života točnije, njihov broj iz 2015.godine.

- **Diplomirani studenti u razdoblju 20-24 godine** - pripada skupini indikatora obrazovanja, kao statistički pokazatelj prikazuje postotak diplomiranih studenata dobiven omjerom diplomiranih studenata prema popisu stanovništva iz 2011.godine i stanovništvom u razdoblju od 20-24. godine.

2.3.2. Ekonomski indikatori

- **Zaposlenost i plaće**

Broj zaposlenih u posljednjih nekoliko godina odraz je gospodarske krize tj. broj zaposlenih u 2015. bio manji u odnosu na 2008.godinu u svim županijama. Broj zaposlenih najviše je smanjen u Gradu Zagrebu, Osječko-baranjskoj i Splitsko–dalmatinskoj županiji. U relativnom smislu najveći pad ostvaren je u Virovitičko-podravskoj i Koprivničko-križevačkoj županiji, a najmanje u Gradu Zagrebu (-7,5%).

Tablica 1: Ukupno zaposleni u Republici Hrvatskoj stanje 31. ožujka 2015.

ŽUPANIJE	2008.	2015.	2015.-2008.
GZG	421.585	389.888	-31.697
ZGŽ	85.924	76.605	-9.319
KZŽ	38.888	33.326	-5.562
VŽ	66.114	59.259	-6.855
KKŽ	38.736	29.818	-8.918
MŽ	40.240	35.392	-4.848
BBŽ	36.462	28.683	-7.779
VPŽ	24.240	18.294	-5.946
PSŽ	20.967	16.754	-4.213
BPŽ	41.427	31.973	-9.454
OBŽ	97.203	76.556	-20.647
VSŽ	46.683	38.399	-8.284
KŽ	41.157	33.786	-7.371
SMŽ	47.919	37.550	-10.369
PGŽ	118.109	100.844	-17.265
LSŽ	14.117	12.887	-1.230
ZDŽ	48.162	44.133	-4.029
ŠKŽ	31.308	29.706	-3.602
SDŽ	146.500	128.528	-17.972
IŽ	89.241	75.363	-13.878
DNŽ	41.184	37.082	-4.102

Kod situacije kretanja nezaposlenosti drugačije je: najveći relativni rast nezaposlenih je kod Krapinsko-zagorske županije (73,7%), Zagrebačke županije (67%), i Grada Zagreba(49,2%), a samo je u dvije županije zabilježen pad (Zadarska i Karlovačka).[31]

Tablica 2: Broj nezaposlenih u Republici Hrvatskoj , stanje 31. ožujka 2015.

ŽUPANIJE	2008.	2015.	2015.-2008.
GZG	27.808	41.484	13.676
ZGŽ	10.184	17.012	6.828
KZŽ	4.140	7.191	3.051
VŽ	7.151	8.350	1.199
KKŽ	6.293	7.336	1.043
MŽ	5.260	6.084	824
BBŽ	10.949	12.916	1.967
VPŽ	8.420	10.218	1.798
PSŽ	5.039	5.937	898
BPŽ	13.619	14.254	635
OBŽ	27.423	35.931	8.508
VSŽ	17.669	19.425	1.756
KŽ	11.474	10.669	-805
SMŽ	15.879	19.676	3.797
PGŽ	14.353	17.690	3.337
LSŽ	3.27	3.919	642
ZDŽ	10.366	9.514	-852
ŠKŽ	7.627	8.398	771
SDŽ	34.688	45.383	10.695
IŽ	6.446	8.236	1.790
DNŽ	7.426	9.588	2.162

Izvor: DZS; obrada: HGK

[31] www.hgk.hr

Tablica 3: Prosječna mjesečna neto plaća u HRK

ŽUPANIJE	2008.	2015.	2015.-2008.
GZG	6.040	6.451	411
ZGŽ	4.960	5.389	429
KZŽ	4.411	4.740	329
VŽ	4.292	4.440	148
KKŽ	4.635	5.109	474
MŽ	4.133	4.553	420
BBŽ	4.421	4.663	242
VPŽ	4.267	4.599	332
PSŽ	4.457	4.706	249
BPŽ	4.464	4.855	391
OBŽ	4.600	5.024	424
VSŽ	4.501	4.774	273
KŽ	4.876	5.246	370
SMŽ	4.857	5.121	264
PGŽ	5.193	5.538	345
LSŽ	4.777	5.002	225
ZDŽ	4.996	5.279	283
ŠKŽ	4.889	5.118	229
SDŽ	4.947	5.260	313
IŽ	5.106	5.463	357
DNŽ	5.055	5.516	461

Izvor: DZS; obrada: HGK

Podaci o distribuciji neto plaća po županijama pokazuje da su najveće prosječne neto plaće u 2015. godini zabilježene u Gradu Zagrebu, Primorsko- goranskoj i Dubrovačko- neretvanskoj županiji. Pritom je uočljiva velika razlika između najviše (Grad Zagreb) i najniže (Varaždinska županija) koja iznosi približno 45 %. (Tablica 3).[32]

[32] www.hgk.hr

- **BDP i gospodarska snaga županija**

Bruto domaći proizvod sveobuhvatni je pokazatelj gospodarstva neke države. BDP u Hrvatskoj objavljuje se na razini cijele države i na razini županije. BDP na razini županija pokazuje prostornu raspodjelu gospodarske aktivnosti, a u slučaju RH ta prostorna raspodjela pokazuje velike razlike u gospodarstvu tj. u razvijenosti županija.

U 2015. Godini nominalni BDP iznosio je 328,1 miljardu kuna, što je 0,4 % manje u odnosu na 2013. Godinu. Najveći apsolutni pad (-733,4 milijuna kuna) zabilježen je u Primorsko-goranskoj županiji, a najveći pad (-6,8%) zabilježen je u Virovitičko-podravskoj županiji. Grad Zagreb i dalje ima najveći udio (33,3%) u ukupnom BDP-u RH, dok Ličko-senjska županija ima najmanji udio (0,9%). U gradu Zagrebu u 2015.godini zabilježen je pad nominalnog BDP-a (-138,2 milijuna kuna) koji je bio znatno manji nego 2013. godini (-1,1 miljardu kuna). Postojanje značajnih razlika u razvijenosti županija RH prikazuje podatak da je nominalni BDP Grada Zagreba (RH regija sa najvećim BDP-om) 37,6 puta veći u odnosu na BDP Ličko-senjske županije (RH regija sa najmanjim BDP-om). Razlika u razvijenosti još je i veća u 2015.godini nego što je bila 2008. godine (31) put.

Razlike između županija uočljive su i prema BDP-u po stanovniku. Najveći iznos tog pokazatelja bilježi se u Gradu Zagrebu, a najmanji u Virovitičko-podravskoj županiji. Tako da je najviši BDP po stanovniku 3,2 puta veći u odnosu na najniži.[33] Jedina županija u kojoj je porastao BDP po stanovniku od pred krizne 2008. do 2015. godine za (1,4%) je Šibensko-kninska, iza koje slijedi Međimurska, koja se 2015. godine izjednačila s razinom BDP-a po stanovniku iz 2008. godine.[34]

Smanjivanje razlika u razvijenosti županija u RH i općenito poboljšanje može se postići adekvatnim iskorištavanjem sredstava fondova EU. Sredstva fondova EU koja su na raspolaganju mogu biti dobar alat smanjenu razlika jer je njihova iskorištenost još uvijek niska.

[33] https://www.hgk.hr/documents/aktualna-tema-bdp-po-zupanijama
[34] http://hrvatska-danas.com/2017/07/04/analiza-bdp-a-po-hrvatskim-zupanijama-i-komparacija-s-regijama-eu-pokazuje-pravu-katastrofu/

Tablica 4: BDP po stanovniku u 2015.godini u HRK

ŽUPANIJA	BDP PO STANOVNIKU U 2015.GOD
GRAD ZAGREB	136.640
ISTARSKA	97.083
PRIMORSKO-GORANSKA	95.743
DUBROVAČKO-NERETVANSKA	77.652
MEĐIMURSKA	66.271
KOPRIVNIČKO-KRIŽEVAČKA	65.342
VARAŽDINSKA	64.458
ZADARSKA	62.540
ŠIBENSKO-KNINSKA	61.561
OSJEČKO-BARANJSKA	61.380
ZAGREBAČKA	60.229
LIČKO-SENJSKA	59.680
SPLITSKO-DALMATINSKA	59.573
KARLOVAČKA	58.213
SISAČKO-MOSLAVAČKA	56.529
BJELOVARSKO-BILOGORSKA	53.502
KRAPINSKO-ZAGORSKA	49.906
VUKOVARSKO-SRIJEMSKA	44.993
POŽEŠKO-SLAVONSKA	44.458
BRODSKO-POSAVSKA	43.191
VIROVITIČKO-PODRAVSKA	43.145

Izvor: DZS; obrada: HGK

- **HGK indeks razvijenosti županija**

Hrvatska gospodarska komora provela je postupak ocjenjivanja i razvrstavanja svih županija u Republici Hrvatskoj prema indeksu gospodarske snage.

HGK Indeks gospodarske snage jest kompozitni pokazatelj koji se računa kao zbroj ponderiranih osnovnih gospodarskih pokazatelja u trogodišnjim prosjecima te demografske projekcije radi mjerenja stupnja gospodarske snage i gospodarskog potencijala županija u odstupanju od prosjeka RH .

Indeks gospodarske snage iznad 100 pokazuje da je pojedina županija u odstupanju od prosjeka RH, dok vrijednost niža od 100 znači da je pojedina županija ispod prosjeka RH. Ovim se sustavom ocjenjivanja i razvrstavanja dobiva analitička podloga za praćenje promjena u stupnju gospodarske razvijenosti županija. HGK indeks se izračunava kao zbroj ponderiranih rangova šest gospodarskih pokazatelja te projekcije kretanja stanovništva:

- BDP po stanovniku
- Ukupni prihod poduzetnika po zaposlenom
- Prosječne neto plaće
- Neto dobit poduzetnika po zaposlenom
- Prihod na inozemnom tržištu poduzetnika po zaposlenom
- Stopa nezaposlenosti
- Projekcija rasta stanovništva 2013.-2030.

Indeks je napravljen s namjerom pozicioniranja županija u odnosu jedne prema drugima, a izražen je kao odnos prema prosjeku RH. Pokazatelji koji su sastavnica indeksa izraženih prema prosjeku RH te sam indeks nalaze se u idućoj tablici.[35]

[35] https://www.hgk.hr/documents/upanijevelikegospodarskerazlikenamalomprostoru

Tablica 5: Indeks gospodarske snage županija i njegove sastavnice

	Bdp po stanovniku,prosjek 2011-2013	Prosječne neto plaće po zaposlenom,prosjek 2012.-2014.	Ukupni prihodi poduzetnika po zaposlenom, prosjek 2013.-2015.	Neto dobit poduzetnika po zaposlenom,prosjek 2013.-2015.	Prihod na inozemnom tržištu po zaposlenom,prosjek 2013.-2015.	Stopa nezaposlenosti,prosjek 2013.-2015.	Demografija-indexpromjene br stanovnika 2030./2013.	HGK INDEKS
GZG	179,3	116,7	131,8	130,9	104,6	199,6	102,6	**149,3**
IŽ	124,5	98,9	84,4	143,4	140,7	178,1	98,7	**127,2**
PGŽ	124,8	100,1	74,3	72,0	89,5	126,5	92,0	**105,1**
VŽ	80,9	80,2	77,8	61,1	144,3	139,8	89,8	**96,2**
DNŽ	95,9	98,8	64,5	105,4	69,9	100,8	94,9	**93,1**
ZGŽ	75,8	95,5	113,8	80,9	95,6	102,4	97,8	**92,5**
ZDŽ	79,5	96,4	75,6	84,7	103,1	100,4	100,4	**91,1**
KKŽ	88,0	92,6	81,5	75,7	100,7	92,6	91,3	**90,1**
MŽ	81,9	81,5	61,3	58,8	111,7	121,1	93,7	**89,2**
KŽ	74,7	95,9	70,6	123,8	87,9	83,2	78,5	**85,5**
KZŽ	61,0	85,9	76,3	74,5	134,6	104,8	88,0	**85,4**
SDŽ	77,0	95,1	75,1	88,6	59,2	76,3	99,0	**82,2**
ŠKŽ	77,0	92,6	69,6	71,9	77,0	85,6	81,5	**80,3**
SMŽ	78,3	93,2	72,5	38,3	155,9	59,8	68,0	**79,6**
OBŽ	79,2	91,6	84,6	62,1	81,3	64,1	86,0	**79,2**
LSŽ	76,4	90,9	58,5	54,4	50,3	88,9	82,7	**75,0**
VSŽ	58,9	87,1	97,4	70,9	81,5	58,7	76,9	**72,6**
BPŽ	56,9	88,3	66,1	49,4	106,4	59,6	81,1	**70,0**
PSŽ	59,7	87,3	57,8	47,0	71,6	71,6	84,5	**68,5**
VBŽ	60,0	84,3	67,5	49,0	82,9	57,2	83,1	**68,2**
BBŽ	67,0	84,1	65,5	41,5	45,9	67,6	80,7	**66,9**

Izvor: DZS, FINA, Ekonomski fakultet : Demografski scenariji i migracije, izračuni HGK

Podaci u tablici 5 pokazuju da se samo Grad Zagreb, Istarska županija te Primorsko-goranska nalaze iznad prosjeka RH, dok je preostalih osamnaest ispod prosjeka. Najniže pozicionirane su Bjelovarsko-bilogorska, Virovitičko- podravska i Požeško-slavonska županija. Županijama sa nižim indeksom gospodarske snage uočava se potreba ulaganja u njihov razvoj s ciljem smanjivanja razlika između županija.

- **Poslovanje poduzetnika po županijama**

Poduzetnici svake županije su važan dio gospodarskog potencijala županije i RH, njihovi financijski rezultati utječu na ukupna gospodarska kretanja kako u županiji tako i u ostalom području RH. Financijski rezultati poslovanja poduzetnika temelj su svakog gospodarstva. Analiza stanja poduzetnika pruža niz informacija za istraživanje kvantitativne i kvalitativne dinamike hrvatskog poduzetništva. Po svom teritorijalnom položaju kao i ekonomskoj strukturi svaka županija je specifična i različita, pa su i financijski pokazatelji uspješnosti poslovanja po županijama različiti. Veliku razliku pojedinih županija prikazuju i podaci u tablici 6. Prema Fininim podacima , najviše poduzetnika dolazi iz Grada Zagreba, Splitsko-dalmatinske , Zagrebačke i Primorsko-goranske županije. Ujedno se te županije ostvarile najveću dobit za navedenu godinu (2015.) [36]

Tablica 6: Poslovanje poduzetnika u 2015.godini

RH županije	Broj poduzetnika	Broj zaposlenih	Ukupan prihod u mil.HRK
GZG	35.089	330.102	328.040
ZGŽ	6.529	47.988	43.975
KZŽ	1.829	18.378	10.128
VŽ	3.202	38.182	22.643
KKŽ	1.829	18.378	10.128
MŽ	2.626	25.316	12.074
BBŽ	1.629	14.073	7.225
VPŽ	881	7.197	3.470
PSŽ	727	7.957	3.472
BPŽ	1.660	15.089	7.941
OBŽ	4.561	37.475	24.299
VSŽ	1.617	17.217	13.870
KŽ	1.931	15.371	8.361
SMŽ	1.819	16.147	9.298
PGŽ	9.436	60.070	34.763
LSŽ	703	4.017	1.856
ZDŽ	3.597	21.095	12.548
ŠKŽ	2.052	11.570	5.381
SDŽ	11.957	70.498	40.559
IŽ	9.552	46.092	30.746
DNŽ	3.705	19.539	9.428

Izvor: FINA, obrada: HGK

[36] https://hgk.hr/documents/upanijevelikegospodarskerazlikenamalomprostoru5757722c5b20e65.pdf

2.3.3. Indikatori infrastrukture

- **Razvijenost opće infrastrukture –** infrastruktura se tipično odnosi na tehničke strukture i sustave koji podržavaju društvo kao npr. ceste, vodovod, kanalizacija, elektroopskrba, itd.

- **Izgrađenost željezničke mreže –** predstavlja razinu učinkovitosti i prijevoznu sposobnost na temelju osiguranih financijskih sredstava za upravljanje i nadzor, održavanje i obnovu, te modernizaciju željezničke mreže.

- **Razvijenost lučkih objekata –** razvijenost lučkih objekata stvara jedan od preduvjeta kontinuiranog i održivog gospodarskog rasta. Količina i pouzdanost infrastrukture su ključni čimbenici sposobnosti neke države da se natječu u međunarodnoj trgovini.

- **Kvaliteta i sigurnost opskrbe električnom energijom -** pokazuje kvalitetu opskrbe električnom energijom, način mjerenja i prikupljanja pokazatelja opskrbe električnom energijom.

3. VIŠEKRITERIJALNO ODLUČIVANJE

3.1. Pojam i karakteristike višekriterijalnog odlučivanja

Pojam višekriterijalnog odlučivanja (Multiple Criteria Decision Making – MCDM) odnosi se na donošenje odluka u prisutnosti mnogih, najčešće konfliktnih kriterija. Većina problema koji pripadaju MCDM ustvari su uobičajeni problemi iz svakodnevnog života. Očito je da problemi kojima se bavi MCDM mogu biti veoma raznovrsni i pripadati različitim područjima ljudske aktivnosti. Međutim, usprkos raznovrsnosti svi ti razmatrani problemi imaju neke zajedničke karakteristike. To su prije svega:

1) Višestrukost kriterija

   Svaki problem MCDM ima više kriterija. Prvi, i često najvažniji posao donosioca odluke je uopće odabrati relevantne kriterije da bi se problem mogao konkretno postaviti. U ovom slučaju raspolaže se sa dostupnim kriterijima izabranim u skladu sa temom rada.

2) Konflikti među kriterijima

   Veći broj kriterija najčešće su u međusobnom konfliktu (suprotnosti).

3) Neusporedive jedinice mjere

Svaki kriterij najčešće ima svoju jedinicu mjere. Mogu biti izražene brojčano npr. Koeficijent zaduženosti ili opisno.

Postoje mnogi razlozi rastućeg interesa za višekriterijalno odlučivanje. Prvi najvažniji je saznanje da je većina problema odlučivanja sama po sebi višekriterijalna. Drugi važan razlog pojačanog interesa je izuzetan razvoj mogućnosti, brzine, kapaciteta, i fleksibilnosti računskih strojeva. Naime, algoritmi za rješavanje višekriterijalnih problema uglavnom zahtijevaju više memorije i vremena računala nego jednokriterijalni modeli. Pored toga većina višekriterijalnih algoritama zahtijeva interaktivni pristup, tj. komunikaciju donosioca odluke i računala. Taj interaktivni pristup zahtijeva brze odgovore od računala, a i prilagodljivost stroja i programa pomoću kojeg se izvodi algoritam.

U višekriterijalnom odlučivanju važnu ulogu igra i donosilac odluke. Donosilac je osoba čije preferencije istraživač – analitičar treba modelirati u namjeri da se odabere najbolje kompromisno rješenje danog višekriterijalnog problema.

Rješenje problema višekriterijalnog odlučivanja uglavnom je dvojako:

a) Dizajniranje najbolje alternative;
b) Izbor najbolje između prethodno specifiranog konačnog broja alternativa.

Problemi višekriterijalnog odlučivanja najčešće se dijele na dva područja:

1. Višekriterijalno programiranje ili višekriterijalna analiza - problemi kod kojih postoji veliki broj alternativa, a koristi se za dizajniranje najbolje alternative.
2. Višeatributivna analiza ili odlučivanje - problemi sa manjim brojem alternativa, a koristi se za izbor najbolje alternative.

Osnovna karkteristika problema višekriterijalnog odlučivanja je da obično postoji ograničen broj unaprijed određenih alternativa. Potrebno je odrediti najbolju alternativu na temelju ocjena svih alternativa po više kriterija. Alternative imaju uz sebe pridružen nivo dostizanja svakog atributa, koji ne mora nužno biti kvalificiran, na temelju čega će se i donijeti konačna odluka. Ta konačna odluka, tj.

a) izbor najbolje alternative,
b) rang i poredak alternativa,
c) izbor skupa najboljih alternativa,

donosi se na temelju usporedbi alternativa po svim atributima (kriterijima) istovremeno. Klasifikacija metoda višeatributivnog odlučivanja najčešće se vrši na temelju količine, načina i oblika informacija o prefrencijama koje su dobivene od donosioca odluke. U problemima i metodama višeatributivnog odlučivanja najčešće se spominju pojmovi kao što su kriteriji, atributi, ciljevi. Pod kriterijima se najčešće podrazumijevaju numeričke funkcije koje treba maksimizirati ili minimizirati, pod atributima osobine, odnosno svojstva pojedinih alternativa, a pod ciljevima prethodno zadane vrijednosti ili nivoi koje želimo postići. Ciljevi se moraju ostvariti, prebaciti ili ne premašiti, pa ih često razmatramo u obliku ograničenja tako da mogu ograničiti ili suziti skup alternativa. Jedna od osnovnih pojmova višeatributivnog odlučivanja je tzv. tablica odluke. Tablica odluke je matrica tipa (m,n) (m redaka, n stupaca) čiji element X_{ij} određuje procjenu *i*-te alternative A_i u odnosu na *j*-ti kriterij X_j, dakle matrica oblika:[37]

[37] Babić, Z.(2011): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split, str. 30.

$$D = \begin{array}{c} \\ A_1 \\ A_2 \\ \vdots \\ A_m \end{array} \begin{array}{c} \begin{array}{cccc} X_1 & X_2 & \cdots & X_n \end{array} \\ \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \dots & \vdots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix} \end{array}$$

Alternativa A_i određena je pritom i-tim retkom matrice D, tj.

$$A_i = [\ x_{i1} \quad x_{i2} \quad \cdots \quad x_{in}\ ]$$

Daje ocjenu *i*-te alternative po svim kriterijima (atributima).

Analogno j-ti stupac matrice D pokazuje ocjene svih alternativa o *j*-tom atributu, odnosno

$$X_j = \begin{bmatrix} x_{1j} \\ x_{2j} \\ \vdots \\ x_{mj} \end{bmatrix}.$$

3.2. Formiranje matrice odluke

U matrici odluke u sljedećoj tablici županije su poredane jedna ispod druge, i svakoj je pridružena skraćena oznaka od A1 do A21 (redom: A1- Grad Zagreb, A2- Zagrebačka županija, A3-Krapinsko-zagorska županija, A4 - Varaždinska županija, A5 - Koprivničko-križevačka županija, A6- Međimurska županija, A7- Bjelovarsko-bilogorska, A8- Virovitičko-podravska, A9 - Požeško-slavonska, A10 - Brodsko–posavska, A11 – Osječko-baranjska, A12 - Vukovarsko-srijemska, A13 - Karlovačka, A14- Sisačko-moslavačka, A15- Primorsko-goranska, A16- Ličko-senjska, A17- Zadarska, A18 - Šibensko-kninska; A19- Splitsko-dalmatinska, A20 - Istarska, A21 - Dubrovačko-neretvanska županija), kao i broju kriterija na temelju kojih se vrši usporedba od f1 do f14. Konačna odluka PROMETHEE metode bit će izbor najbolje alternative, te rang svih alternativa.

Matrica odluke koja je sastavljena za potrebe ovog rada prikazana je u sljedećoj tablici br.7.

Tablica 7: Matrica odluke

		f1	f2	f3	f4	f5	f6	f7	f8	f9	f10	f11	f12	f13	f14
	KRITERIJI	VŠS	VSS	UP.STUD	DLSTUD	BDP CAPITA	NEZAP.	ZAPOSL.	PROSJ.PL	POS.POD	HGK	INFRAST.	ŽELJEZN.	LUČ.OB	ELE.ENER
		%	%	%	%										
		Max	Max	Max	Max	Max	Min	Max	Max	Max	Max	Max	Max	Max	Max
A1	GZG	6.2	9.5	50.6	12.2	136640	41484	389888	6451	328040	149.3	4.8	4	2.7	5.4
A2	ZGŽ	5.4	6.2	45.6	11.4	60229	17012	76605	5389	43975	92.5	3.2	2.1	3	4.9
A3	KZŽ	5.8	7.4	44.6	10.4	49906	7191	33326	4740	10128	85.4	3.7	3.3	2.9	5.1
A4	VŽ	7	9.1	54.5	14.1	64458	8350	59259	4440	22643	96.2	3.7	3.3	1.4	5.3
A5	KKŽ	5.9	8.8	47.5	11.4	65342	7336	29818	5109	10128	90.1	5.4	4.4	2.8	5.9
A6	MĐŽ	5.8	7.9	50.7	11.3	66271	6084	35392	4553	12074	89.2	4.1	4.4	1.8	6.3
A7	BBŽ	4.8	7.1	47.4	10.8	53502	12916	28683	4663	7225	66.9	3.2	2.1	3.7	5.3
A8	VPŽ	8.5	15.7	68.1	17.2	43145	10218	18294	4599	3470	68.2	4.4	2.7	4.3	5.6
A9	PSŽ	7.2	7	52	12.2	44458	5937	16754	4706	3472	68.5	3.7	2.7	2.7	4.6
A10	BPŽ	4.4	6	43.2	9.5	43191	14254	31973	4855	7941	70	4.1	3.4	2.7	5.5
A11	OBŽ	5.7	8.3	55.4	10.1	61380	35931	76556	5024	24299	79.2	2.9	1.8	2.3	5.3
A12	VSŽ	4.7	7.3	47	10.5	44993	19425	38399	4774	13870	72.6	4.6	4.5	3.8	5.4
A13	KŽ	7.8	13.1	52.6	12.8	58213	10669	33786	5246	8361	85.5	4.6	3.4	5.1	5.6
A14	SMŽ	5.3	10.9	47	10.8	56529	19676	37550	5121	9298	79.6	4	3.5	3.9	5.9
A15	PGŽ	7.5	9.4	55.4	17.2	95743	17690	100844	5538	34763	105.1	3.6	2.8	3.9	4.3
A16	LSŽ	5.2	6.9	43.1	9.7	59680	3919	12887	5002	1856	75	3.8	3.5	4.1	5.4
A17	ZDŽ	8.5	14	63.5	15.8	62540	9514	44133	5279	12548	91.1	3.9	2.8	4.7	4.8
A18	ŠKŽ	8.3	11.8	52.5	12.7	61561	8398	29706	5118	5381	80.3	4.3	2	3.2	4.2
A19	SDŽ	10.3	14.8	59.9	14.3	59573	45383	128528	5260	40559	82.2	3.8	1.5	4.6	3.3
A20	ISŽ	5.7	7.8	48.8	11.2	97083	8236	75363	5463	30746	127.2	5.6	3.5	1.7	6.3
A21	DNŽ	8.3	26.8	75.2	17.9	77652	9588	37082	5516	9428	93.1	3.1	4.4	3.1	5.9

Izvor: Izrada autora

3.3. Procjena važnosti kriterija

Temeljem podataka iz matrice odluke, donositelj odluke mora odlučiti koja alternativa, tj. županija predstavlja najbolji izbor. Ta odluka se donosi uz pomoć različitih metoda. Budući da se višekriterijalno odlučivanje temelji na većem broju kriterija koji su često u konfliktnom odnosu i nisu svi jednako važni važnost kriterija ovisit će o preferencijama donositelja odluke što je povezano sa njegovim vrijednosnim sustavom. Svaka od 21 alternative se treba analizirati po svakom od 14 odabranih kriterija.

U najpoznatije metode procjene važnosti za jedinstvenog donosioca odluke spadaju metoda entropije, ponderirana metoda najmanjih kvadrata i metoda svojstvenog vektora koja će se koristiti u ovom slučaju.

3.3.1. Metoda svojstvenog vektora

Ovu metodu je razvio Thomas L. Satty, jedna je od najkorištenijih i najkorektnijih metoda za procjenu težina kriterija. Metoda svojstvenog vektora traži od donosioca odluke usporedbu kriterija i na temelju svojih preferencija on mora donijeti odluku o relativnoj važnosti pojedinog kriterija u odnosu na druge tj. usporediti sve moguće parove kriterija i odlučiti koliko neki kriterij više doprinosi postizanju željenog cilja. Pri usporedbi parova kriterija (X_i,X_j) on se može odlučiti na jednu od sljedeće tri tvrdnje:

a) Oba kriterija su jednako važna; što pri kvantifikaciji omjera važnosti kriterija w_i i w_j znači da je $a_{ij} = \frac{wi}{wj} = 1$.
b) Kriterij X_i je važniji od kriterija X_j, ako kvantificiramo omjer važnosti kriterija $w_i w_j$ dobit ćemo $a_{ij} = \frac{wi}{wj} > 1$. Znači da donosilac odluke ima preferenciju za višu školu nad visokom školom.
c) Kriterij X_j je važniji od kriterija X_i, a kvantifikacijom omjera kriterija se dobije $a_{ij} = \frac{wi}{wj} < 1$.

Procjena kriterija može se izraziti brojčano ali kada se postavlja pitanje o intenzitetu preferencije, tj. koliko je donosiocu odluke jedan kriterij više ili manje važniji od drugog.

U tome nam pomaže Saatyeva skala koja je omjerna skala i sastoji se od pet stupnjeva i četiri međustupnja.[38]

Tablica 8: Saatyeva skala važnosti i njen opis

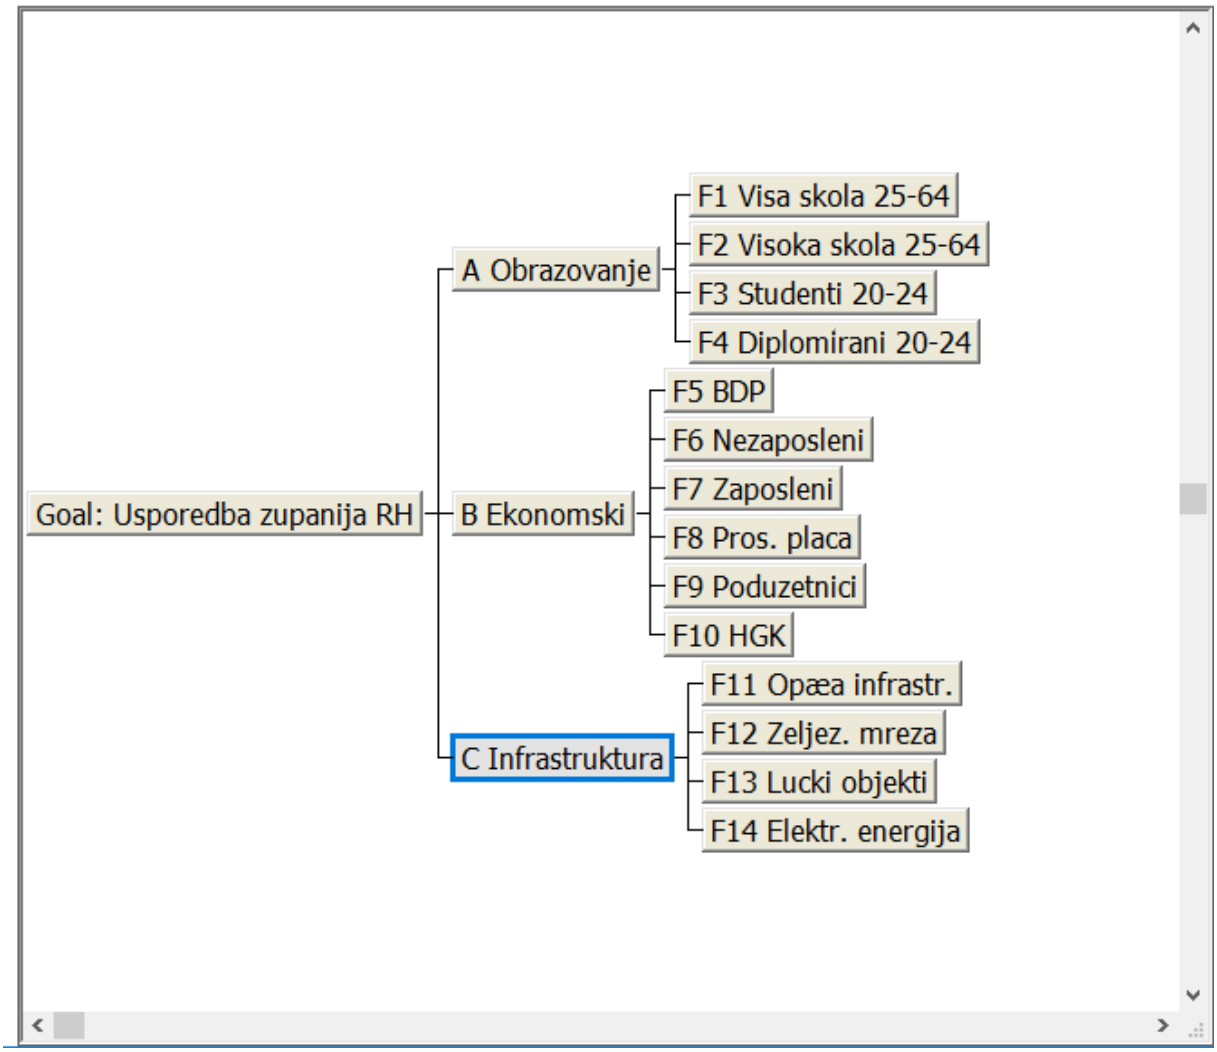
INTEZITET VAŽNOSTI	DEFINICIJA	OBJAŠNJENJE
1	Jednaka važnost	Dva kriterija jednako pridonose cilju
3	Slaba preferencija jednog nad drugim	Iskustvo i prosudbe slabo favoriziraju jedan kriterij nad drugim
5	Bitna ili jaka preferencija	Iskustvo i prosudbe jako favoriziraju jedan kriterij nad drugim
7	Uvjerljiva preferencija	Jedan kriterij je u prednosti nad drugim i njegova dominacija je dokazana u praksi
9	Apsolutna preferencija	Očita prednost najvišeg mogućeg ranga jednog kriterija nad drugim
2,4,6,8	Međuvrijednosti između dviju susjednih parova	Kada je potreban kompromis

Izvor: Saaty, T. (2001.); Decision making for leaders – The analytic hierarchy process for decision in a complex world, RWS Publications, Pitsburgh USA

Pomoću ove skale kriteriji se uspoređuju po parovima, a kao rezultat se dobije tablica procjene važnosti A čiji su elementi upravo te procjene a_{ij}.

[38] Babić, Z.(2011): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split., str.74.

3.3.1.1. Procjena važnosti kriterija aproksimativnim postupkom



Slika 2: Podjela kriterija unutar skupina

Izvor: Izrada autora

Kriterije smo podijelili u 3 grupe prema odluci autora. Grupa A i C imaju jednak broj kriterija 4, dok se B razlikuje sa dva dodatna kriterija odnosno 6. U ovom slučaju postoje 3 matrice A,B,C sa pripadajućim f kriterijima. Matrice A, B, C su pozitivne i recipročne tj. svaki element iznad glavne dijagonale jednak je recipročnoj vrijednosti svog simetričnog elementa ispod glavne dijagonale.

Svi elementi na glavnoj dijagonali imaju vrijednost 1 zato što se radi o usporedbi svakog elementa unutar matrice sa samim sobom. Teškoće koje se javljaju prilikom procjene kriterija je nekonzistentnost. U tu svrhu računa se vrijednost indeksa konzistencije CI.

$$\mathbf{CI} = \frac{\boldsymbol{\lambda max} \quad \mathbf{-n}}{\mathbf{n-1}}$$

I omjera konzistencije CR:

CR= CI/RI

gdje je RI slučajni indeks, odnosno indeks konzistencije za matrice reda n slučajno generiranih usporedbi u parovima. U našem slučaju RI za A i C grupu kriterija je 0.89 jer je n (broj kriterij) 4. Za B grupu indeks konzistencije iznosi 1.25 jer u tom slučaju ima 6 kriterija unutar same matrice.

Svaka od prethodno spomenutih matrica je konzistentna tj. za svaku vrijedi CR ≤0,10. Do toga smo došli rješavajući problem u programskom paketu Excel Office te dobili težine svakog kriterija.

Uspoređivali smo prvo tri grupe međusobno, kriterije obrazovanja, ekonomije i infrastrukture, a zatim pokazatelje unutar svake grupe**.** Prikazana je usporedba kriterija i njihove težine. Svaki element iznad glavne dijagonale jednak je recipročnoj vrijednosti svog simetričnog elementa ispod glavne dijagonale.

Vidi se da je donosilac odluke prednost dao kriteriju ekonomije, slijedi kriterij obrazovanja i posljednji infrastruktura.

	OBRAZOVANJE	**EKONOMIJA**	**INFRASTRUKT.**
OBRAZOVANJE	**1,00**	0,50	3,00
EKONOMIJA	2,00	**1,00**	5,00
INFRASTRUKT.	0,33	0,20	**1,00**
SUMA	3,33	1,70	9,00

	OBRAZOVANJE	**EKONOMIJA**	**INFRASTRUKT.**	**Wj**
OBRAZOVANJE	0,30	0,29	0,33	**0,309**
EKONOMIJA	0,60	0,59	0,56	**0,581**
INFRASTRUKT.	0,10	0,12	0,11	**0,110**

INDIKATORI OBRAZOVANJA- A

Poredak važnosti kriterija za donosioca odluke je diplomirani studenti, upisani studenti u razdoblju 20-24 godine, visoka škola, te viša škola u populaciji 25-64 godine. Za dobiti vrijednosti težina kriterija, određuje se matrica međusobnih usporedbi ta 4 kriterija a težine će se odrediti metodom svojstvenog vektora. Svaki element iznad glavne dijagonale jednak je recipročnoj vrijednosti svog simetričnog elementa ispod glavne dijagonale. Na primjer, ako je kriterij viša škola preferiran od upisanih studenata te mu je dodijeljena ocjena 4; iz toga slijedi da su upisani studenti 4 puta "lošiji" od kriterija više škole te im pripada vrijednost 1/4.

	VIŠA ŠKOLA	VISOKA ŠKOLA	UPISANI STUDENTI	DIPLOM.STUDENTI
VIŠA ŠKOLA	**1.0**	2.0	4.0	0.5
VISOKA ŠKOLA	0.5	**1.0**	3.0	0.2
UPISANI STUDENTI	0.3	0.3	**1.0**	0.1
DIPLOM.STUDENTI	2.0	5.0	7.0	**1.0**
SUMA	3.8	8.3	15.0	1.8

Nakon dijeljenja svih elemenata sa sumom stupca dobivamo tablicu gdje se konačne vrijednosti težina dobivaju kao prosječne vrijednosti svakog retka te matrice:

	VIŠA ŠKOLA	VISOKA ŠKOLA	UPISANI STUDENTI	DIPLOM.STUDENTI	Wj
VIŠA ŠKOLA	0.3	0.2	0.3	0.3	**0.261**
VISOKA ŠKOLA	0.1	0.1	0.2	0.1	**0.140**
UPISANI STUDENTI	0.1	0.0	0.1	0.1	**0.063**
DIPLOM.STUDENTI	0.5	0.6	0.5	0.5	**0.536**

Svaki se kriterij iz prethodne tablice množi sa svojom dodijeljenom težinom gdje nakon toga možemo izračunati najveću svojstvenu vrijednost λmax koja se dobije kao prosječna vrijednost stupca λ I.

	VIŠA ŠKOLA	VISOKA ŠKOLA	UPISANI STUDENTI	DIPLOM.STUDENTI	SUMA	WJ	λ I
VIŠA ŠKOLA	0.3	0.3	0.3	0.3	1.06	**0.261**	4.061739
VISOKA ŠKOLA	0.1	0.1	0.2	0.1	0.57	**0.140**	4.031733
UPISANI STUDENTI	0.1	0.0	0.1	0.1	0.25	**0.063**	4.007902
DIPLOM.STUDENTI	0.5	0.7	0.4	0.5	2.20	**0.536**	4.105789
						λ MAX	4.051791
						CI	0.017264
						Cra	**0.019397**

Cra= 0.02 ≤0.10

Indeks konzistencije manji je od 0.10 te se time važnosti kriterija smatraju prihvatljivima.

Isti ovakav postupak proveli smo za ostala 2 indikatora (ekonomski, infrastruktura) te se uvjerili da su ocjene omjera važnosti donesene potpuno konzistentno.

EKONOMSKI INDIKATORI – B

Poredak važnosti kriterija za donosioca odluke je BDP po stanovniku, HGK indeks razvijenosti županija, prosječna mjesečna neto plaća, ukupno zaposleni u RH, poslovanje poduzetnika i ukupno nezaposleni u RH. Za dobiti vrijednosti težine kriterija, određuje se matrica međusobnih usporedbi tih 6 kriterija a težine će se odrediti metodom svojstvenog vektora. Svaki element iznad glavne dijagonale jednak je recipročnoj vrijednosti svog simetričnog elementa ispod glavne dijagonale. Na primjer, ako je kriterij BDP po stanovniku preferiran od ukupno nezaposlenih u RH te mu je dodijeljena ocjena 9; iz toga slijedi da su ukupno nezaposleni 9 puta "lošiji" od kriterija BDP po stanovniku te im pripada vrijednost 1/9.

	BDP	UK.NEZAPOSLENI	UK. ZAPOSLENI	PROSJ.PLAĆA	POSLOV.PODUZ	HGK
BDP	**1.0**	9.0	6.0	4.0	8.0	3.0
UK.NEZAPOSLENI	0.1	**1.0**	0.3	0.2	0.5	0.1
UK.ZAPOSLENI	0.2	4.0	**1.0**	0.5	3.0	0.3
PROSJ.PLAĆA	0.3	5.0	2.0	**1.0**	4.0	0.5
POSLOV.PODUZ	0.1	2.0	0.3	0.3	**1.0**	0.2
HGK	0.3	7.0	4.0	2.0	5.0	**1.0**
SUMA	2.0	28.0	13.6	8.0	21.5	5.1

	BDP	UK.NEZAPOSLENI	UK.ZAPOSLENI	PROSJ.PLAĆA	POSLOV.PODUZ	HGK	Wj
BDP	0.5	0.3	0.4	0.5	0.4	0.6	**0.455**
UK.NEZAPOSLENI	0.1	0.0	0.0	0.0	0.0	0.0	**0.031**
UK.ZAPOSLENI	0.1	0.1	0.1	0.1	0.1	0.0	**0.092**
PROSJ.PLAĆA	0.1	0.2	0.1	0.1	0.2	0.1	**0.144**
POSLOV.PODUZ	0.1	0.1	0.0	0.0	0.0	0.0	**0.046**
HGK	0.2	0.3	0.3	0.3	0.2	0.2	**0.232**

	BDP	UK.NEZAPOSLENI	UK.ZAPOSLENI	PROSJ.PLAĆA	POSLOV.PODUZ	HGK	SUMA	Wj	λ I
BDP	0.5	0.3	0.6	0.6	0.4	0.7	2.93	**0.455**	6.43
UK.NEZAPOSLENI	0.1	0.0	0.0	0.0	0.0	0.0	0.19	**0.031**	6.10
UK.ZAPOSLENI	0.1	0.1	0.1	0.1	0.1	0.1	0.56	**0.092**	6.09
PROSJ.PLAĆA	0.1	0.2	0.2	0.1	0.2	0.1	0.90	**0.144**	6.25
POSLOV.PODUZ	0.1	0.1	0.0	0.0	0.0	0.0	0.28	**0.046**	6.04
HGK	0.2	0.2	0.4	0.3	0.2	0.2	1.49	**0.232**	6.40
								λ MAX	6.22
								CI	0.04
								CRb	**0.03**

CRb = 0.03 ≤0.10

INDIKATORI INFRASTRUKTURE – C

Poredak važnosti kriterija za donosioca odluke je kvaliteta i sigurnost električne energije, razvijenost opće infrastrukture, izgrađenost željezničke mreže i razvijenost lučkih objekata. Za dobiti vrijednosti težina kriterija, određuje se matrica međusobnih usporedbi ta 4 kriterija a težine će se odrediti metodom svojstvenog vektora. Svaki element iznad glavne dijagonale jednak je recipročnoj vrijednosti svog simetričnog elementa ispod glavne dijagonale. Na primjer, ako je kriterij razvijenost opće infrastrukture preferiran od izgrađenosti željezničke mreže te mu je dodijeljena ocjena 2; iz toga slijedi da je kriterij izgrađenost željezničke mreže 2 puta "lošiji" od kriterija razvijenosti opće infrastrukture te mu pripada vrijednost 1/2.

	RAZV. OPĆ.INFR	IZGRAĐ.ŽELJEZ.MR	RAZV.LUČKIH OBJEK.	KV. I SIG.ELEKT.ENERG
RAZV. OPĆ.INFR	**1.0**	2.0	5.0	0.5
IZGRAĐ.ŽELJEZ.MR	0.5	**1.0**	2.0	0.2
RAZV.LUČKIH OBJEK.	0.2	0.5	**1.0**	0.1
KV. I SIG.ELEKT.ENERG	2.0	5.0	7.0	**1.0**
SUMA	3.7	8.5	15.0	1.8

	RAZV OPĆ.INFR	IZGRAĐ.ŽELJEZ.MR	RAZV.LUČKIH OBJEK.	KV. I SIG.ELEKT.ENERG	Wj
RAZV. OPĆ.INFR	3.7	17.0	75.0	0.9	**24.155**
IZGRAĐ.ŽELJEZ.MR	1.9	8.5	30.0	0.4	**10.180**
RAZV.LUČKIH OBJEK.	0.7	4.3	15.0	0.3	**5.063**
KV. I SIG.ELEKT.ENERG	7.4	42.5	105.0	1.8	**39.186**

	RAZV OPĆ.INFR	IZGRAĐ.ŽELJEZ.MR	RAZV.LUČKIH OBJEK.	KV. I SIG.ELEKT.ENERG	SUMA	Wj	λ I
RAZV. OPĆ.INFR	24.2	20.4	25.3	19.6	89.42	**24.155**	3.70
IZGRAĐ.ŽELJEZ.MR	12.1	10.2	10.1	7.8	40.22	**10.180**	3.95
RAZV.LUČKIH OBJEK.	4.8	5.1	5.1	5.6	20.58	**5.063**	4.06
KV. I SIG.ELEKT.ENERG	48.3	50.9	35.4	39.2	173.84	**39.186**	4.44
						λ MAX	4.04
						CI	0.01
						CRc	**0.01**

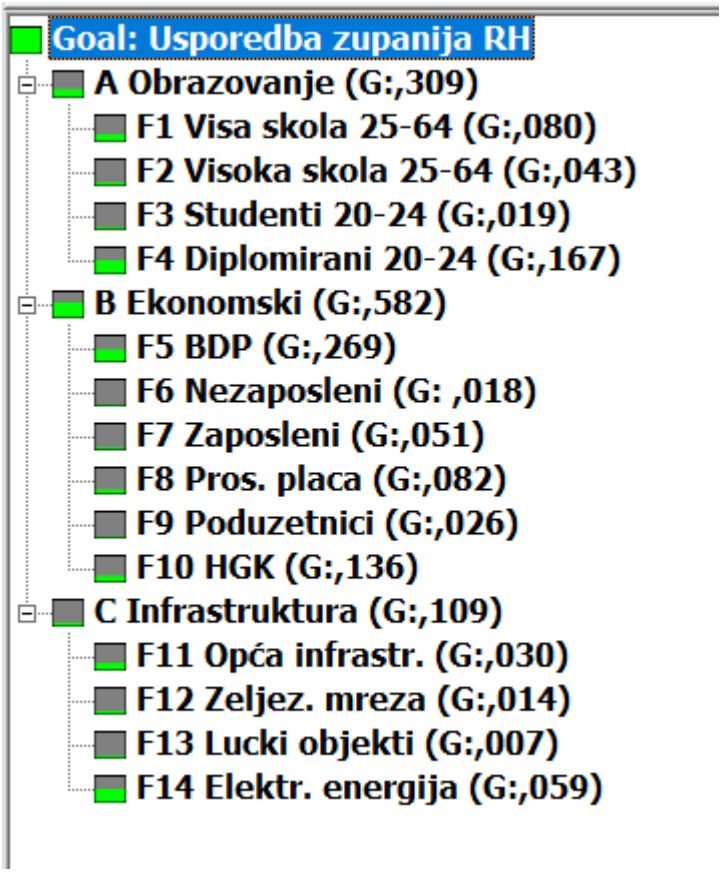
Crc = 0.01 ≤ 0.1

S obzirom na izračunate omjere konzistencije zaključuje se da su procjene iz matrice zadovoljavajuće.

3.3.1.2. Expert Choice

Primjena metode svojstvenog vektora zahtijeva prilično mukotrpnog posla. Međutim, zahvaljujući veoma dobrim softverskim paketima (prvenstveno Expert Choice) primjena te metode je vrlo jednostavna, odnosno potrebno je samo prikupiti podatke za matricu međusobnih usporedbi kriterija, a sav ostali posao obavlja računalni program koji kao finalni rezultat daje težine kriterija.[39]

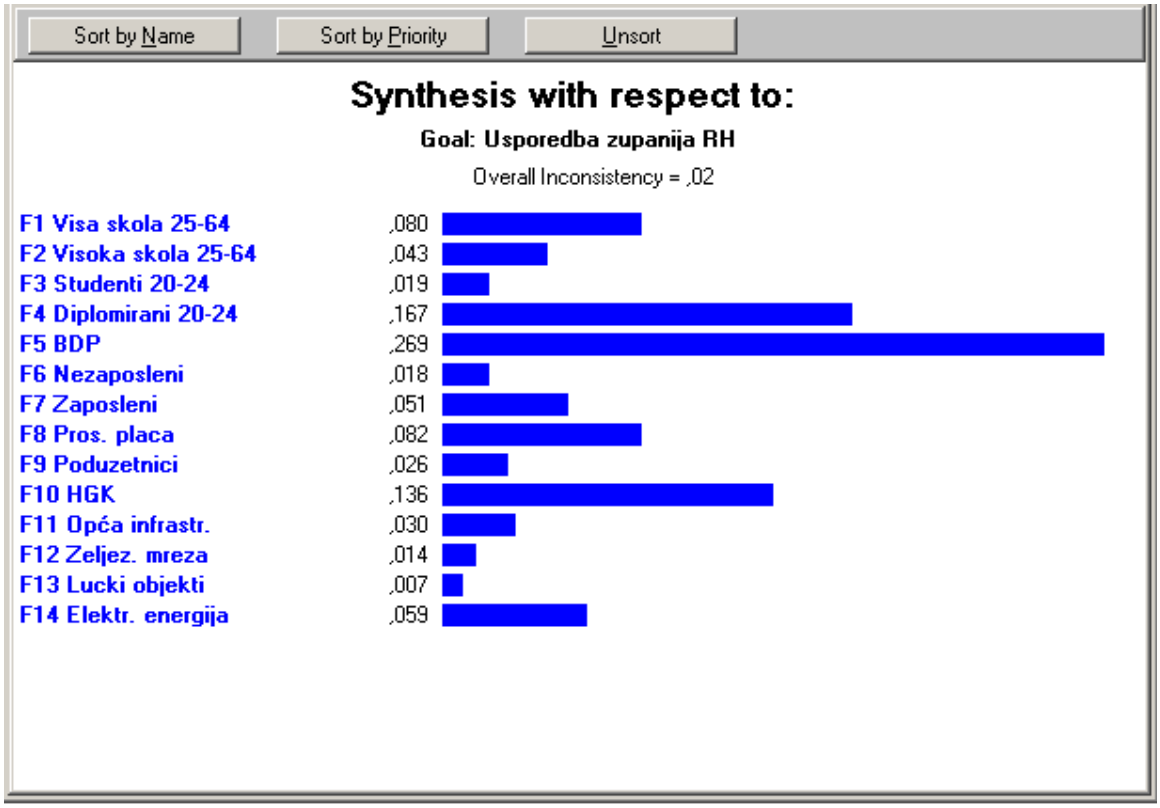
Dobivene težine kriterija aproksimativnim postupkom vrlo su slične onima koje se dobiju u programu Expert Choice, no za PROMETHEE metodu koristili su se rezultati programa Expert Choice radi svoje preciznosti, i jednostavnosti.



Slika 3: Težine kriterija unutar programa Expert Choice

Izvor: Expert Choice

[39] Babić, Z.(2011): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split., str.78.



Slika 4: Grafički prikaz težina kriterija unutar programa Expert Choice

Izvor: Expert Choice

Na slici 4 prikazane su težine kriterija dobivene kao izlazni rezultat programa Expert Choice, a one predstavljaju težine za PROMETHEE metodu. Najvažnija tri kriterija sa produženim težinama su dohodak po stanovniku, diplomirani studenti u razdoblju od 20-24 godine, i indeks gospodarske razvijenosti (HGK). Najmanje važni kriteriji su razvijenost lučkih objekata (0,7%) te izgrađenost željezničke mreže (1,4%).

4. PRIMJENA PROMETHEE METODE

4.1. PROMETHEE metoda

PROMETHEE I (parcijalni rang) i PROMETHEE II (kompletni rang) razvili su Belgijanci J.P. Brans, Ph. Vincke i B. Mareschal i predstavljeni su prvi put 1982. na konferenciji koju su organizirali R. Nadeau i M. Landry na Sveučilištu Laval u Quebecu u Kanadi. To je metoda koju koristimo za izbor najbolje alternative kod višekriterijalnog odlučivanja. Metodu PROMETHEE 1 koristimo kada želimo prikazati djelomičan poredak alternative, međutim on daje mnogo realnije informacije, pogotovo one vezane za neusporedivost koje često mogu biti od velike važnosti za konačno donošenje odluke. Metodu PROMETHEE II koristimo za potpuni poredak. Njezine prednosti su: jednostavnost, postojanje ekonomskog objašnjena i značaja korištenih parametara.[40]

U ovom radu veliki broj alternativa (21) predstavlja problem koji treba riješiti, u tom slučaju PROMETHEE metoda daje kvalitetnije rezultate istraživanja.[41]

Razmotrimo prvo višekriterijalni problem oblika:

Max $\{f_1(a), f_2(a) \ldots, f_n(a) \mid a \in A\}$

gdje je A konačan skup alternativa (aktivnosti), tj. A= {A1,A2,…,A_m}, a f_j su n kriterija koje treba maksimizirati. Svaki kriterij je funkcija iz A u R ili u neki drugi uređeni skup. Neka je za svaku aktivnost A_i, f_j(Ai) vrijednost ili procjena vrijednosti j-tog kriterija za i-tu alternativu.

Kada uspoređujemo dvije alternative a i b (A_k i A_l) moramo biti sposobni rezultat te usporedbe izraziti u terminima preferencija. Iz tih se razloga uvodi funkcija preferencije P:

$P : A \, XA \rightarrow [\, 0, 1 \,]$

koja predstavlja intenzitet preferencije alternative (aktivnosti) a u odnosu na alternativu b na sjedeći način:

P(a,b) = 0 znači indiferenciju između a i b, ili nepostojanje između preferencije od a nad b,

P(a,b) ≈ 0 znači slabu preferenciju od a nad b,

P(a,b) ≈ 1 znači jaču preferenciju od a nad b,

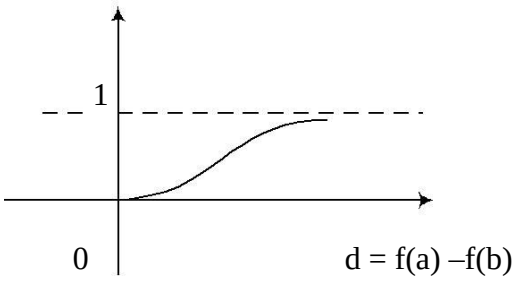
[40] Babić, Z.(2011): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split.
[41] Z. Babić, B.Grčić: "Multicriterial Evaluation of County and Macroregional Development in Croatia", Central

P(a,b) = 1 znači striktnu preferenciju od a nad b.

Funkcija preferencije koja se pridružuje pojedinom kriteriju je funkcija razlike kriterijalnih vrijednosti (ocjena) alternativa po nekom atributu (kriteriju):

d= f(a) – f(b)

Možemo uzeti da je P(a,b)= P(d) i tada graf funkcije preferencije ima sljedeći oblik:



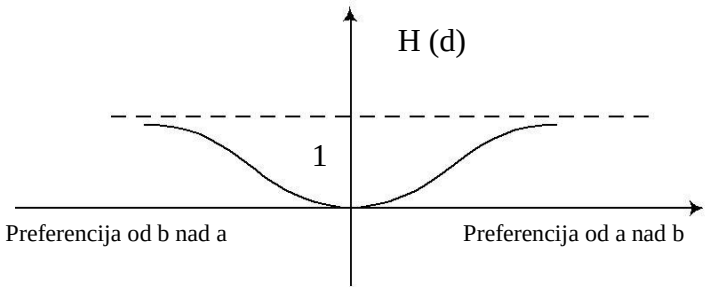
Slika 5: Graf funkcije preferencije

Funkcija preferencije je neopadajuća funkcija, koja je jednaka nuli za negativne vrijednosti od d. Naime, ako je d≤ 0,tj. f(a) ≤ f(b), tada ne postoji preferencija od a nad b pa je i P(a,b) =0. Što je razlika u ocjenama tih dviju alternativa (d) veća to je P (a,b) bliži jedinici, a za određenu vrijednost od d funkcija postaje jednaka 1 jer dolazi do striktne preferencije.

Da bi imali bolji pregled područja indiferencije može se promatrati funkcija H (d) koja je direktno vezana sa funkcijom preferencije P na sljedeći način:

$$H(d) = \begin{cases} P(a,b), & d \geq 0 \\ P(b,a), & d < 0 \end{cases}$$

Sljedeći izraz predstavlja funkciju preferencije H (d):



Slika 5: Funkcija preferencije H (d)

Za svaki kriterij *fj* razmatra se zatim generalizirani kriterij definiran pomoću *fj* i odgovarajuće funkcije preferencije. Autori metode predložili su šest različitih tipova generaliziranog kriterija. Unutar PROMETHEE metode potrebno je unaprijed odrediti neke parametre, od kojih svako ima stvarno ekonomsko značenje i objašnjenje.[42] To su :

q- prag indiferencije, koji definira područje unutar kojeg je razlika vrijednosti dviju alternativa po nekom kriteriju zanemariva za donosioca odluke,

p- prag indiferencije, koji definira područje stroge preferencije,

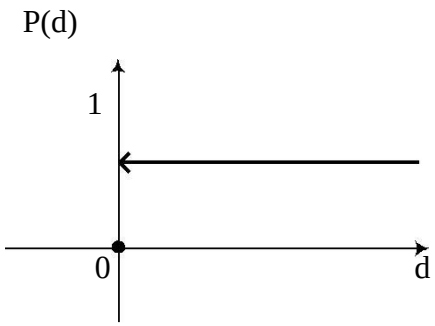
s – parametar čija vrijednost se nalazi između praga indiferencije q i praga preferencije p.

Tih šest tipova generaliziranog kriterija su :

1. **Obični kriterij**

$$P(d) = \begin{cases} 0, & d \le 0 \\ 1, & d > 0 \end{cases}$$

U tom slučaju indiferencija između a i b postoji ako i samo ako f(a)=f(b), tj. za d = 0. Čim su procjene po tim dvjema aktivnostima različite to znači da donosilac odluke striktno preferira aktivnost koja ima veću ocjenu, pa je vrijednost funkcije preferencije jednaka 1. Ta funkcija preferencije prikazana je na slici.



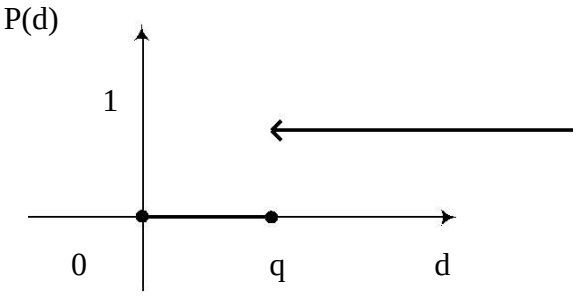
Slika 6: Obični kriterij

[42] Z.Babić, B.Grčić: "Evaluation of relative Development Level for Croatian Counties", Zbornik radova KOI '98, Rovinj, 1998, p. 39-48.

2. **Kvazi kriterij**

$$P(d) = \begin{cases} 0, & d \le q \\ 1, & d > q \end{cases}$$

Kao što se vidi na slici kod tog kriterija uvodi se prag indiferencije q, tj. dvije alternative su indiferentne tako dugo dok razlika njihovih ocjena ne premaši prag q, a u protivnom postoji stroga preferencija. Dakle, ako donosilac odluke želi upotrijebiti takvu funkciju preferencije potrebno je odrediti vrijednost parametra q koji ima strogo ekonomsko značenje.



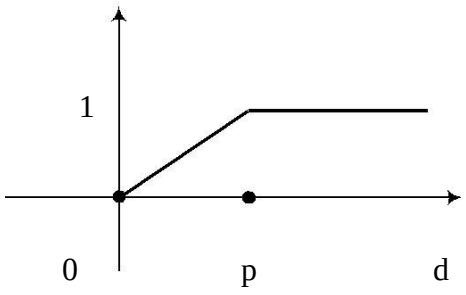
Slika 7: Kvazi kriterij

2. Kriterij s linearnom preferencijom

$$P(d) = \begin{cases} 0, & d \le 0 \\ \dfrac{d}{p}, & d < p \\ 1, & d \ge p \end{cases}$$

Dok je d manji od parametra p preferencija donosioca odluke raste linearno s vrijednošću d. Čim razlika *d* postaje veća od *p* postoji situacija stroge preferencije.

Za taj kriterij treba dakle odrediti također samo jedan parametar p koji predstavlja najnižu vrijednost razlike u ocjenama dviju alternativa iznad koje imamo strogu preferenciju.

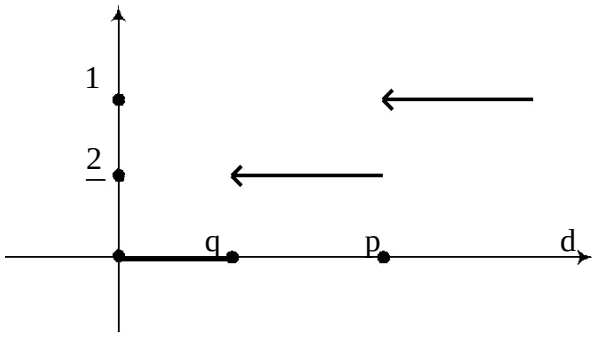


Slika 8: Kriterij s linearnom preferencijom

3. **Nivo kriterij**

$$P(d) = \begin{cases} 0, & d \le q \\ \frac{1}{2}, & q < d \le p \\ 1, & d > p \end{cases}$$

U tom slučaju potrebno je definirati oba praga q i p i kada se razlika d nalazi između njihovih vrijednost tzv. Slaba preferencija (P(d) = ½).

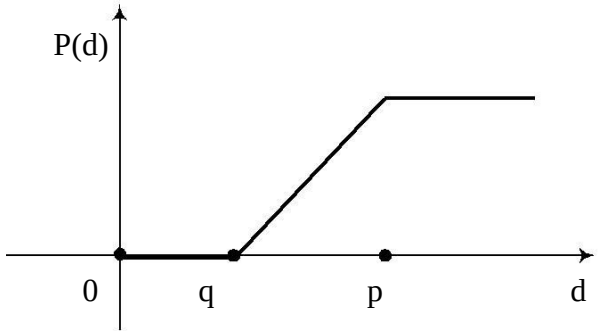


Slika 9: Nivo kriterij

4. **Kriterij s linearnom preferencijom i područjem indiferencije**

$$P(d) = \begin{cases} 0, & d \le q \\ \frac{d-q}{p-q}, & q < d \le p \\ 1, & d > p \end{cases}$$

Preferencija donosioca odluke, u tom slučaju, raste linearno u području indiferencije do područja stroge preferencije, tj. u području između pragova q i p.

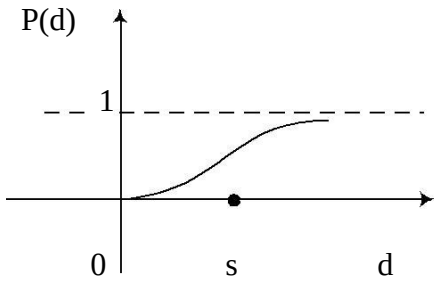


Slika 10: Kriterij s linearnom preferencijom i područjem indiferencije

5. Gaussov kriterij

$$P(d) = \begin{cases} 0, & d \le 0 \\ 1 - e^{-d^{2/2s^2}}, & d > 0 \end{cases}$$

Ta funkcija zahtijeva definiranje samo parametra s koji leži negdje u području slabe preferencije, a predstavlja ustvari standardnu devijaciju normalne razdiobe. Ta funkcija koja nema prekida ni "šiljaka" može biti interesantna zbog eventualne stabilnosti rezultata.



Slika 11: Gaussov kriterij

4.2. Ulazni i izlazni tok

Izlazni ili pozitivni tok

$$\Phi^{+}(a) = \sum_{b \in A} \Pi(a, b)$$

Predstavlja sumu vrijednosti svih lukova koji izlaze iz čvora (alternative) a, i zato izražava mjeru koliko alternativa a dominira nad svim ostalim alternativama (b $\in$ A) po svim kriterijima, odnosno pokazuje koliko je alternativa a bolja od svih ostalih alternativa.

Možemo reći da ϕ^{+} (a) mjeri snagu alternativa a.

Ulazni ili negativni tok

$$\Phi^{-}(a) = \sum_{b \in A} \Pi(b, a)$$

Pokazuje koliko je a dominirana od svih ostalih alternativa i po svim kriterijima. Dakle ϕ^{-} (a) mjeri slabost alternative *a* odnosno što je ϕ^{-} (a) manji to je alternativa bolja.

Usporedbom ulaznih i izlaznih tokova dobivaju se dva potpuna uređaja skupa alternativa, tj. jedan po ϕ^{+} (a) i jedan po ϕ^{-} (a) . To su :

$$\phi^{+}(a)\left\{\begin{array}{llllllll} aS^{+}b & ako & i & samo & ako & je & \phi^{+}(a) > \phi^{+}(b) \\ aI^{+}b & ako & i & samo & ako & je & \phi^{+}(a) = \phi^{+}(b) \end{array}\right\}$$

$$\phi^{-}(a)\begin{cases} aS^{-}b & ako\ \ i\ \ samo\ \ ako\ \ je & \Phi^{-}(a) < \Phi^{-}(b) \\ aI^{-}b & ako\ \ i\ \ samo\ \ ako\ \ je & \Phi^{-}(a) = \Phi^{-}(b) \end{cases}$$

Pri čemu je S tzv." outranking" relacija, tj. a S b znači *: a* je barem toliko dobar kao i *b* ili bolji.

Presjek tih dvaju uređaja rezultira u parcijalnom uređaju (P, I, R) što je konačan uređaj dobiven metodom PROMETHEE 1. Taj uređaj prikazan je u sljedećoj tablici.

Tablica 9 : PROMETHEE 1 –parcijalni uređaj

a P b (a dominira nad b)	ako i samo ako $\begin{cases} aS^{+}b & i & aS^{-}b \\ & ili & \\ aS^{+}b & i & aI^{-}b \\ & ili & \\ aI^{+}b & i & aS^{-}b \end{cases}$
a I b (a je indiferentan sa b)	Ako i samo ako aI^{+} b i aI^{-} b
a R b (a i b su neusporedivi)	u ostalim slučajevima

Ako donosilac odluke želi potpuni uređaj skupa alternativa A može se izračunati tzv. neto tok ϕ, kao razlika "snage" i "slabosti" pojedine alternative tj.

ϕ(a) = $\phi^{+}(a) - \phi^{-}(a)$.

Takav se uređaj naziva PROMETHEE II. Iako je donositelju odluke jednostavnije odlučivati na temelju potpunog poretka (PROMETHEE II) ipak parcijalni uređaj (PROMETHEE I) daje realnije informacije, pogotovo one vezane za neusporedivost koje često mogu biti od velike važnosti za konačno donošenje odluke.

4.3. Ulazni podaci za PROMETHEE metodu

Za rješavanje metode PROMETHEE postoji kvalitetan i vizualno atraktivan softver Decision Lab, kojeg proizvodi kanadska tvrtka Viusal Decision.

Ulazni podaci za rad u programu Decision Lab prikazani su na slici 12.

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	Criterion13	Criterion14
Min/Max	Maximize	Maximize	Maximize	Maximize	Maximize	Minimize	Maximize	Maximize	Maximize	Maximize	Maximize	Maximize	Maximize	Maximize
Weight	80.0000	43.0000	19.0000	167.0000	269.0000	18.0000	51.0000	82.0000	26.0000	136.0000	30.0000	14.0000	7.0000	59.0000
Preference Function	V-Shape	Level	Linear	U-Shape	Linear	V-Shape	V-Shape	Level	Linear	Level	Gaussian	Linear	Gaussian	V-Shape
Indiference Threshold	-	1.0000	5.0000	2.0000	3000.0000	-	-	400.0000	1000.0000	1000.0000	-	0.7000	-	-
Preference Threshold	5.9000	4.0000	25.0000	-	40000.0000	40000.0000	250000.0000	1500.0000	20000.0000	5000.0000	-	2.5000	-	3.0000
Gaussian Threshold	-	-	-	-	-	-	-	-	-	-	0.8000	-	1.5000	-
Threshold Unit	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute	Absolute
Average Performance	6.5857	10.2762	52.6000	12.5476	90099.4762	15200.5238	63563.1429	5087.9048	30485.9524	87.9619	4.0238	3.1476	3.2571	5.2524
Standard Dev.	1.5777	4.7557	8.2831	2.5752	115828.4946	11743.3626	80276.4643	454.1706	69298.8133	19.8963	0.7056	0.9081	1.0166	0.7222
Unit														
A1	6.2000	9.5000	50.6000	12.2000	136640.0000	41484.0000	389888.0000	6451.0000	328040.0000	149.3000	4.8000	4.0000	2.7000	5.4000
A2	5.4000	6.2000	45.6000	11.4000	60229.0000	17012.0000	76605.0000	5389.0000	43975.0000	92.5000	3.2000	2.1000	3.0000	4.9000
A3	5.8000	7.4000	44.6000	10.4000	49906.0000	7191.0000	33326.0000	4740.0000	10128.0000	85.4000	3.7000	3.3000	2.9000	5.1000
A4	7.0000	9.1000	54.5000	14.1000	64458.0000	8350.0000	59259.0000	4440.0000	22643.0000	96.2000	3.7000	3.3000	1.4000	5.3000
A5	5.9000	8.8000	47.5000	11.4000	65342.0000	7336.0000	29818.0000	5109.0000	10128.0000	90.1000	5.4000	4.4000	2.8000	5.9000
A6	5.8000	7.9000	50.7000	11.3000	66271.0000	6084.0000	35392.0000	4553.0000	12074.0000	89.2000	4.1000	4.4000	1.8000	6.3000
A7	4.8000	7.1000	47.4000	10.8000	53502.0000	12916.0000	28683.0000	4663.0000	7225.0000	66.9000	3.2000	2.1000	3.7000	5.3000
A8	8.5000	15.7000	68.1000	17.2000	43145.0000	10218.0000	18294.0000	4599.0000	3470.0000	68.2000	4.4000	2.7000	4.3000	5.6000
A9	7.2000	7.0000	52.0000	12.2000	44458.0000	5937.0000	16754.0000	4706.0000	3472.0000	68.5000	3.7000	2.7000	2.7000	4.6000
A10	4.4000	6.0000	43.2000	9.5000	43191.0000	14254.0000	31973.0000	4855.0000	7941.0000	70.0000	4.1000	3.4000	2.7000	5.5000
A11	5.7000	8.3000	55.4000	10.1000	61380.0000	35931.0000	76556.0000	5024.0000	24299.0000	79.2000	2.9000	1.8000	2.3000	5.3000
A12	4.7000	7.3000	47.0000	10.5000	44993.0000	19425.0000	38399.0000	4774.0000	13870.0000	72.6000	4.6000	4.5000	3.8000	5.4000
A13	7.8000	13.1000	52.6000	12.8000	58213.0000	10669.0000	33786.0000	5246.0000	8361.0000	85.5000	4.6000	3.4000	5.1000	5.6000
A14	5.3000	10.9000	47.0000	10.8000	586529.0000	19676.0000	37550.0000	5121.0000	9298.0000	79.6000	4.0000	3.5000	3.9000	5.9000
A15	7.5000	9.4000	55.4000	17.2000	95743.0000	17690.0000	100844.0000	5538.0000	34763.0000	105.1000	3.6000	2.8000	3.9000	4.3000
A16	5.2000	6.9000	43.1000	9.7000	59680.0000	3919.0000	12887.0000	5002.0000	1856.0000	75.0000	3.8000	3.5000	4.1000	5.4000
A17	8.5000	14.0000	63.5000	15.8000	62540.0000	9514.0000	44133.0000	5279.0000	12548.0000	91.1000	3.9000	2.8000	4.7000	4.8000
A18	8.3000	11.8000	52.5000	12.7000	61561.0000	8398.0000	29706.0000	5118.0000	5381.0000	80.3000	4.3000	2.0000	3.2000	4.2000
A19	10.3000	14.8000	59.9000	14.3000	59573.0000	45383.0000	128528.0000	5260.0000	40559.0000	82.2000	3.8000	1.5000	4.6000	3.3000
A20	5.7000	7.8000	48.8000	11.2000	97083.0000	8236.0000	75363.0000	5463.0000	30746.0000	127.2000	5.6000	3.5000	1.7000	6.3000
A21	8.3000	26.8000	75.2000	17.9000	77652.0000	9588.0000	37082.0000	5516.0000	9428.0000	93.1000	3.1000	4.4000	3.1000	5.9000

Slika 12: ulazni podaci za PROMETHEE metodu

Izvor: Izrada autora

Na slici su prikazani ulazni podatci za PROMETHEE metodu tj. za svaki od kriterija od A1 do A21 pripadajuće težine kriterija, funkcije preferencije s parametrima, te radi li se o kriteriju kojeg treba maksimizirati ili minimizirati.

4.3.1. Popis generaliziranih kriterija i pripadajućih parametara

Tablica 10: Popis generaliziranih kriterija i pripadajućih parametara

KRITERIJ	f1	f2	f3	f4	f5	f6	f7	f8	f9	f10	f11	f12	f13	f14
TIP FUNKCIJE PREFERENCIJE	III	IV	V	II	V	III	III	IV	V	IV	VI	V	VI	III
PARAMETRI	p=5.9	q=1 p=4	q=5 p=25	q=2	q=3000 p=40000	p=40000	p=250000	q=400 p=1500	q=1000 p=20000	q=1000 P=5000	s=0.8	q=0.7 p=2.5	s=1.5	p=3

Izvor: Izrada autora

- Za prvi kriterij viša škola u populaciji 25.-64. godine izabran je kriterij s linearnom preferencijom (III. kriterij). Prag preferencije (p=5.9) što znači da svaka razlika u razlici postotka kriterija dovodi do vrijednosti funkcije preferencije koja je veća od nule. Vrijednost funkcije preferencije raste sve dok razlika u vrijednosti ne bude veća ili jednaka 5.9, a tada nastupa stroga preferencija, tj. vrijednost funkcije preferencije jednaka je 1.
- Za drugi kriterij visoka škola u populaciji 25.-64. god izabran je kriterij tipa IV s pragom indiferencije q=1 i pragom preferencije p=4. To znači da dok je razlika u vrijednostima manja od 1 nema nikakve preferencije, a ako je razlika između 1 i 4 vrijednost preferencije vrijednost funkcije preferencije 3/2. Ako je razlika veća od 4 vrijednost funkcije preferencije jednaka je 1.
- Za treći kriterij upisani studenti u razdoblju 20.-24. godine izabran je V. kriterij s parametrima q=5 i p= 25. To znači da dok je razlika u postotku upisanih studenata između dvije alternative manja od 5 donosilac odluke ih smatra jednako vrijednim po tom kriteriju. Ako razlika pređe 5 i sve do 25 vrijednost funkcije preferencije raste linearno do 1. Razlika veća od 25 dovodi do stroge preferencije, odnosno do vrijednosti funkcije preferencije od točno 1.
- Za četvrti kriterij diplomirani studenti u razdoblju 20.-24. godine izabran je II. tip gdje je prag indiferencije zadan sa q=2. To znači da dok je razlika u postotku diplomiranih studenata samo 1 nema nikakve preferencije između dvije alternative. Čim je razlika veća od 2 ili više preferira se ona županija sa strogom preferencijom, odnosno vrijednošću funkcije preferencije jednakom 1.
- Za peti kriterij BDP po stanovniku zabran je V. tip kriterija s parametrima q=3000 i p=40000. To znači da dok je razlika u postotku upisanih studenata između dvije alternative manja od 3000 donosilac odluke ih smatra jednako vrijednim po tom kriteriju. Ako razlika pređe 3000 i sve do 40000 vrijednost funkcije preferencije raste linearno do 1. Razlika veća od 40000 dovodi do stroge preferencije, odnosno do vrijednosti funkcije preferencije od točno 1.
- Za šesti kriterij ukupno nezaposleni u RH izabran je kriterij s linearnom preferencijom (III. kriterij). Prag preferencije (p=40000) što znači da svaka razlika u vrijednosti kriterija dovodi do vrijednosti funkcije preferencije koja je veća od nule.

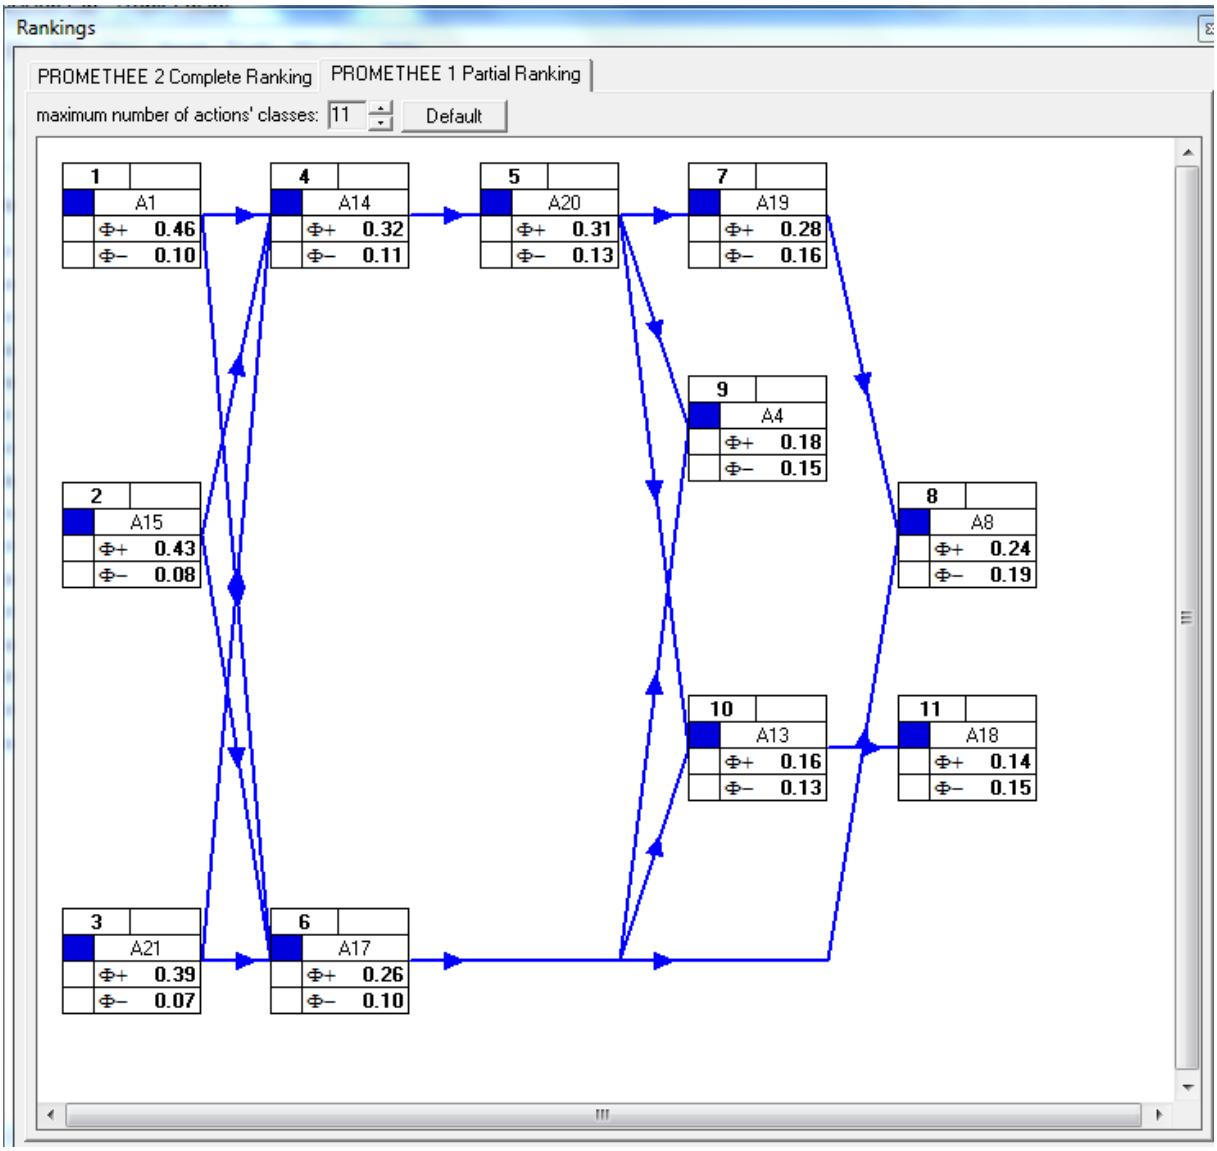
Vrijednost funkcije preferencije raste sve dok razlika u vrijednosti ne bude veća ili jednaka 40000, a tada nastupa stroga preferencija, tj. vrijednost funkcije preferencije jednaka je 1.

- Za sedmi kriterij ukupno zaposleni u RH izabran je kriterij s linearnom preferencijom (III. kriterij). Prag preferencije (p=250000) što znači da svaka razlika u vrijednosti kriterija dovodi do vrijednosti funkcije preferencije koja je veća od nule. Vrijednost funkcije preferencije raste sve dok razlika u vrijednosti ne bude veća ili jednaka 250000, a tada nastupa stroga preferencija, tj. vrijednost funkcije preferencije jednaka je 1.
- Za osmi kriterij prosječna mjesečna neto plaća izabran je kriterij tipa IV s pragom indiferencije q=400 i pragom preferencije p=1500. To znači da dok je razlika u vrijednostima manja od 1 nema nikakve preferencije, a ako je razlika između 400 i 1500 vrijednost preferencije vrijednost funkcije preferencije iznosi 1100/2. Ako je razlika veća od 1500 vrijednost funkcije preferencije jednaka je 1.
- Za deveti kriterij poslovanje poduzetnika izabran je V. kriterij s parametrima q=1000 i p=20000. To znači da dok je razlika poslovanju poduzetnika između dvije alternative manja od 1000 mil. kuna donosilac odluke ih smatra jednako vrijednim po tom kriteriju. Ako razlika pređe 1000 i sve do 20000 mil. kn vrijednost funkcije preferencije raste linearno do 1. Razlika veća od 20000 mil. kn dovodi do stroge preferencije, odnosno do vrijednosti funkcije preferencije od točno 1.
- Za deseti kriterij indeks gospodarske snage županija izabran je IV. kriterij s parametrima q=1000 i p=5000. To znači da dok je razlika u indeksu gospodarske snage županija između dvije alternative manja od 1000 donosilac odluke ih smatra jednako vrijednim po tom kriteriju. Ako razlika pređe 1000 i sve do 5000 vrijednost funkcije preferencije raste linearno do 1. Razlika veća od 5000 dovodi do stroge preferencije, odnosno do vrijednosti funkcije preferencije od točno 1.
- Za jedanaesti kriterij razvijenost opće infrastrukture izabran je VI. tip , odnosno što je razlika vrijednosti dviju alternativa veća vrijednost funkcije preferencije "glatko" raste prema jedinici. Prelazak iz ubrzanog u usporeni rast predviđen je kada je razlika u ocjenama veća od 0,8 jedinica.

- Za dvanaesti kriterij izgrađenost željezničke mreže izabran je V. kriterij s parametrima q=0,7 i p= 2,5. To znači da dok je razlika u postotku upisanih studenata između dvije alternative manja od 0,7 donosilac odluke ih smatra jednako vrijednim po tom kriteriju. Ako razlika pređe 0,7 i sve do 2,5 vrijednost funkcije preferencije raste linearno do 1. Razlika veća od 2,5 dovodi do stroge preferencije, odnosno do vrijednosti funkcije preferencije od točno
- Za trinaesti kriterij razvijenost lučkih objekata izabran je VI. tip , odnosno što je razlika vrijednosti dviju alternativa veća vrijednost funkcije preferencije "glatko" raste prema jedinici. Prelazak iz ubrzanog u usporeni rast predviđen je kada je razlika u ocjenama veća od 1,5 jedinica.
- Za četrnaesti kriterij kvaliteta i sigurnost opskrbe električnom energijom izabran je izabran je kriterij s linearnom preferencijom (III. kriterij). Prag preferencije (p=3) što znači da svaka razlika u vrijednosti kriterija dovodi do vrijednosti funkcije preferencije koja je veća od nule. Vrijednost funkcije preferencije raste sve dok razlika u vrijednosti ne bude veća ili jednaka 3, a tada nastupa stroga preferencija, tj. vrijednost funkcije preferencije jednaka je 1.

4.4. Rezultati istraživanja

4.4.1.PROMETHEE I



Slika 13: PROMETHEE I rang prvih 11 županija

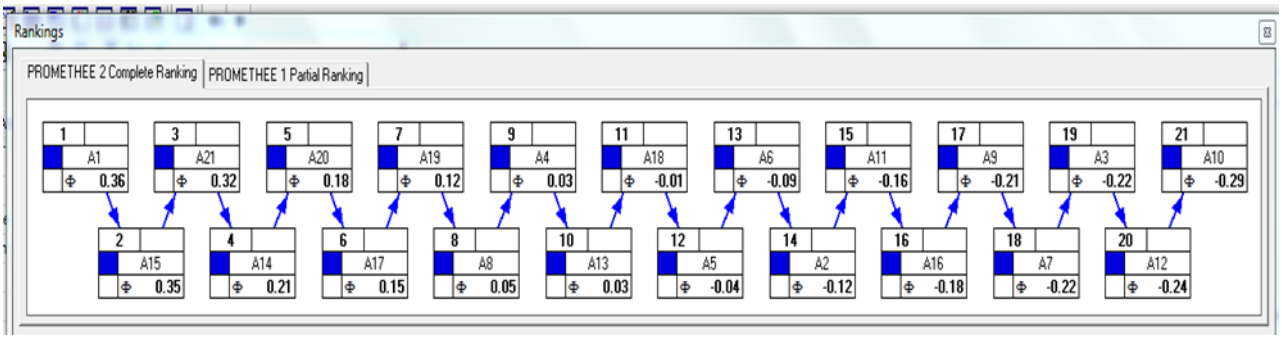
Izvor: Izrada autora

U ovom slučaju imamo rang prvih 11 najboljih županija. Iz te slike lako je uočljivo da je alternativa A1 (Grad Zagreb) najbolja od svih ostalih s obzirom da ima najveći pozitivni tok ϕ=0,46. Zatim slijedi alternativa A15 (Primorsko-goranska), A21 (Dubrovačko-neretvanska), A14 (Sisačko-moslavačka), A20 (Istarska županija), A17 (Zadarska županija), A19 (Splitsko-dalmatinska), A8 (Virovitičko-podravska), A4 (Varaždinska županija), A13 (Karlovačka županija), i A18 (Šibensko-kninska).

- Alternative A1 (Grad Zagreb) i A15 (Primorsko-goranska) su međusobno neusporedive budući da je po pozitivnom toku A1 bolja od A15, a po negativnom nešto lošija.
- Alternative A1 (Grad Zagreb) i A21 (Dubrovačko-neretvanska) su međusobno neusporedive budući da je po pozitivnom toku A1 bolja od A21, a po negativnom nešto lošija.
- Alternative A15 (Primorsko-goranska) i A21 (Dubrovačko-neretvanska) su međusobno neusporedive budući da je po pozitivnom toku A15 bolja, a po negativnom lošija.
- Alternative A14 (Sisačko-moslavačka) i A17 (Zadarska županija) su međusobno neusporedive budući da je po pozitivnom toku A14 bolja, a po negativnom nešto lošija.
- Alternative A19 (Splitsko-dalmatinska) i A4 (Varaždinska županija) su međusobno neusporedive budući da je po pozitivnom toku A19 bolja, a po negativnom nešto lošija.
- Alternative A19 (Splitsko-dalmatinska) i A13 (Karlovačka županija) su međusobno neusporedive budući da je po pozitivnom toku A19 bolja, a po negativnom nešto lošija.
- Alternative A4 (Varaždinska) i A13 (Karlovačka županija) su međusobno neusporedive budući da je po pozitivnom toku A19 bolja, a po negativnom nešto lošija.
- Alternative A8 (Virovitičko-podravska) i A18 (Šibensko-kninska) su međusobno neusporedive budući da je po pozitivnom toku A8 bolja, a po negativnom nešto lošija.

4.4.2. PROMETHEE II

S obzirom da PROMETHEE I nije dao konačan poredak županija jer su neke neusporedive, koristit će se metoda PROMETHEE II. Ako se želi dobiti potpuni poredak alternativa, tj. kompletni rang, upotrijebiti će se metoda PROMETHEE II, odnosno izračunati neto tok ϕ kao razlika pozitivnog i negativnog toka za svaku alternativu. Ta razmatranja prikazana su odgovarajućim grafom u kojem su alternative poredane od najbolje do najgore (po PROMETHEE II uređaju).



Slika 14: PROMETHEE II rang svih alternativa

Izvor: Izrada autora

Alternative su poredane od najbolje do najgore po PROMETHEE II uređaju i taj poredak je :

1. Grad Zagreb
2. Primorsko-goranska županija
3. Dubrovačko-neretvanska županija
4. Sisačko-moslavačka županija
5. Istarska županija
6. Zadarska županija
7. Splitsko-dalmatinska županija
8. Virovitičko-podravska
9. Varaždinska županija
10. Karlovačka županija
11. Šibensko-kninska županija
12. Koprivničko-križevačka županija
13. Međimurska županija
14. Zagrebačka županija
15. Osječko-baranjska županija
16. Ličko-senjska županija
17. Požeško-slavonska županija
18. Bjelovarsko-bilogorska županija
19. Krapinsko-zagorska županija
20. Vukovarsko-srijemska županija
21. Brodsko-posavska županija

Sljedeća slika prikazuje tablični prikaz svih pozitivnih, negativnih i neto tokova za sve alternative unutar programskog paketa Decision Lab.

Preference Flows

	Φ+	Φ−	Φ
A1	0.4561	0.0995	0.3566
A2	0.0760	0.1937	-0.1177
A3	0.0240	0.2485	-0.2245
A4	0.1804	0.1527	0.0277
A5	0.1102	0.1538	-0.0436
A6	0.0894	0.1814	-0.0920
A7	0.0218	0.2443	-0.2225
A8	0.2397	0.1871	0.0526
A9	0.0488	0.2606	-0.2119
A10	0.0199	0.3137	-0.2938
A11	0.0705	0.2277	-0.1572
A12	0.0342	0.2743	-0.2401
A13	0.1551	0.1285	0.0266
A14	0.3223	0.1079	0.2144
A15	0.4333	0.0843	0.3489
A16	0.0471	0.2302	-0.1831
A17	0.2556	0.1010	0.1546
A18	0.1408	0.1521	-0.0114
A19	0.2799	0.1616	0.1184
A20	0.3050	0.1252	0.1798
A21	0.3910	0.0726	0.3183

Slika 15: Pozitivni, negativni i neto tokovi svih alternativa

Izvor: Izrada autora

Da bi se dobio pregledniji prikaz ranga svih alternativa sa njihovim neto tokovima prikazane su u tablici 11.

Tablica 11: Rang alternativa po PROMETHEE II

	ŽUPANIJA	ϕ- neto tok
A1	**Grad Zagreb**	**0,36**
A15	**Primorsko-goranska**	**0,35**
A21	**Dubrovačko-neretvanska**	**0,32**
A14	**Sisačko-moslavačka**	**0,21**
A20	**Istarska**	**0,18**
A17	**Zadarska**	**0,15**
A19	**Splitsko-dalmatinska**	**0,12**
A8	**Virovitičko-podravska**	**0,05**
A4	**Varaždinska**	**0,03**
A13	**Karlovačka**	**0,03**
A18	**Šibensko-kninska**	**-0,01**
A5	**Koprivničko-križevačka**	**-0,04**
A6	**Međimurska**	**-0,09**
A2	**Zagrebačka**	**-0,12**
A11	**Osječko-baranjska**	**-0,16**
A16	**Ličko-senjska**	**-0,18**
A9	**Požeško-slavonska**	**-0,21**
A7	**Bjelovarsko-bilogorska**	**-0,22**
A3	**Krapinsko-zagorska**	**-0,22**
A12	**Vukovarsko-srijemska**	**-0,24**
A10	**Brodsko-posavska**	**-0,29**

Izvor: Izrada autora

ZAKLJUČAK

Prema administrativno-teritorijalnom ustroju RH se sastoji od dvadeset i jedne županije (uključujući Grad Zagreb) , svaka od njih ima utjecaja na gospodarski rast države u cjelini. Po svom teritorijalnom položaju kao i gospodarstvu svaka je specifična i različito razvijena. Županijske razlike su iznimno povećane u zadnjih nekoliko godina , a samim time je ova tema aktualna i kao takva odabrana za provedbu istraživanja. Analizirano razdoblje obuhvaća podatke 2015. godine za ulazne podatke PROMETHEE metode jer se veliki broj pokazatelja temelji na podacima dostupnim za popisnu godinu. U pojedinim pokazateljima objava službenih podataka na razini županije kasni sa objavom podataka na nacionalnoj razini. Teorijski aspekt rada o županijama obuhvaća godine od 2013.-2015.godine . Rad se temelji na preferencijama pojedinca, točnije preferencijama rada autora rada pri čemu je subjektivne naravi.

Kako bi se dobila što jasnija slika stanja kretanja županija napravljena je višekriterijalna analiza županija putem PROMETHEE metode. Prikazano je rješavanje problematike višekriterijalnih problema u programskom paketu Decision Lab koji uz pravilno definirane indikatore te dovoljne informacije o županijama omogućuje izbor najbolje alternative iz definiranog skupa.

Sam proces provodio se korištenjem 14 različitih kriterija odabranih od strane autora rada za 21 županiju. Prvo je korištena metoda svojstvenog vektora kako bi se dokazala konzistentnost procjena važnosti. Nakon toga slijedi postupak unutar Expert Choice-a za dobivanje težina pojedinog kriterija. S dobivenim težinama i određenim parametrima dobiven je konačan poredak putem PROMETHEE metode, alternativa pomoću koje se može donijeti zaključak o izboru najbolje, točnije Gradu Zagrebu koji po svim kriterijima prednjači naspram drugih.

Primjenom PROMETHEE metode može se zaključiti da se hipoteza H1: „Višekriterijalnom analizom moguće je napraviti usporedbu razvijenosti županija“ prihvaća.

Ovaj rad još je jedan dokaz o velikoj teritorijalnoj i gospodarskoj razlici županija unutar RH.

RH bi se trebala decentralizirati oslanjajući se na europske uzore. Decentralizacija bi imala višestruko pozitivne učinke koji bi se očitovali u ravnomjernijem razvitku svih dijelova RH.

LITERATURA

1. Babić, Z.(2011): Modeli i metode poslovnog odlučivanja, Ekonomski fakultet Split, Split.
2. Babić, Z., B.Grčić: "Evaluation of relative Development Level for Croatian Counties", Zbornik radova KOI '98, Rovinj, 1998, p. 39-48.
3. Babić, Z., Grčić, B. (1998): "Multicriterial Evaluation of County and Macro regional Development in Croatia", Central European Journal for Operations Research and Economics, Vol. 6, No 1-2, p. 7-19.
4. Brans, J. P., Mareschal, B. (2005): PROMETHEE Methods, in Figueira, J., Greco, S., Ehrgott, M. (eds.): Multiple Criteria Decision Analysis: State of the Art Surveys, 163-195.
5. Brans, J. P., Mareschal, B., Vincke, P., (1986): How to select and how to rank projects: The PROMETHEE method, European Journal of Operational Research, 24(2), 228-238.
6. Čavrak, V.(2003): Regionalni razvoj i regionalna politika Hrvatske, Hrvatski gospodarski razvoj, Ekonomski fakultet Zagreb i Politička kultura, Zagreb, str.3.
7. Jurun. E., Ratković N: Ekonometrijska financijska analiza poduzetnika Republike Hrvatske i njihova multivarijacijska analiza po županijama u 2004. i 2010. godini.
8. Saaty, T. (2001.); Decision making for leaders – The analiytic hierarchy process for decision a complex world, RWS Publications, Pitsburgh USA.
9. Saaty, T. L. (2005): Theory and Applications of the Analytic Network Process, RWS Publications, Pitsburgh USA.
10. Sikavica, P.(1999): Poslovno odlučivanje, Informator, Zagreb.
11. Tkalac Verčić, A. et al. (2011): Priručnik za metodologiju istraživačkog rada u društvenim istraživanjima: kako osmisliti, provesti i opisati znanstveno i stručno istraživanje, M.E.P., Zagreb.
12. Zelenika, R. (2000): Metodologija i tehnologija izrade znanstvenog i stručnog djela. Ekonomski fakultet Sveučilište u Rijeci, Rijeka, 2000.

Internet izvori

1. Hrvatski zavod za statistiku (**www.dzs.hr**)
2. Financijska agencija (**www.fina.hr**)
3. Hrvatska gospodarska komora (**www.hgk.hr**)
4. Nacionalno vijeće za konkurentnost (**www.konkurentnost.hr**)
5. Ministarstvo regionalnog razvoja i fondova Europske unije (**www.mrrfeu.hr**)
6. Filozofski fakultet Zagreb (**www.ffzg.hr**)
7. Hrvatska danas (**www.hrvatska-danas.com**)

POPIS TABLICA

Tablica 1: Ukupno zaposleni u Republici Hrvatskoj stanje 31. ožujka 2015……....21

Tablica 2: Broj nezaposlenih u Republici Hrvatskoj , stanje 31. ožujka 2015…….....…22

Tablica 3: Prosječna mjesečna neto plaća u HRK……...……23

Tablica 4: BDP po stanovniku u 2015.godini u HRK…….……...……..25

Tablica 5: Indeks gospodarske snage županija i njegove sastavnice……....27

Tablica 6: Poslovanje poduzetnika u 2015.godini……..…….28

Tablica 7: Matrica odluke……..……33

Tablica 8: Saatyeva skala važnosti i njen opis…….……35

Tablica 9: PROMETHEE 1 –parcijalni uređaj…….…….…….50

Tablica 10: Popis generaliziranih kriterija i pripadajućih parametara……..…51

Tablica 11: Rang alternativa po PROMETHEE II……..…59

POPIS SLIKA

Slika 1 : Nova statistička klasifikacija prostornih jedinica RH- NUTS 2 10

Slika 2: Raspored kriterija unutar skupina 36

Slika 3: Težine kriterija dobivene programom Expert Choice 41

Slika 4: Graf funkcije preferencije 41

Slika 5: Funkcija preferencije H (d) 42

Slika 6: Obični kriterij 45

Slika 7: Kvazi kriterij 46

Slika 8: Kriterij s linearnom preferencijom 46

Slika 9: Nivo kriterij 47

Slika 10: Kriterij s linearnom preferencijom i područjem indiferencije 47

Slika 11: Gaussov kriterij 48

Slika 12: Ulazni podaci za PROMETHEE metodu……..51

Slika 13: PROMETHEE I rang prvih 11 županija 55

Slika 14: PROMETHEE II rang svih alternativa……....……..57

Slika 15: Pozitivni, negativni i neto tokovi svih alternativa……..……..58

SAŽETAK

U fokusu ovog rada je višekriterijalna analiza stanja hrvatskih županija. Istraživanje je provedeno na temelju baze podataka koja je bila dostupna na službenim web stranicama. Vremenski horizont je 2013.-2015. godine.

Primijenjena je PROMETHEE metoda , počevši sa metodom svojstvenog vektora radi dobivanja težina kriterija potrebnih za sam proces analize u programskom paketu Decision Lab. Analiza je provedena za svaku 21 županiju sa svih 14 kriterija, podijeljenih u tri grupe po odluci autora rada.

Izlazni podaci PROMETHEE II uređaja ukazuju na veliku raznolikost županija na gospodarskom i teritorijalnom području. Izbor najbolje alternative ove metode je Grad Zagreb.

KLJUČNE RIJEČI: višekriterijalna analiza, PROMETHEE metoda, županije, izbor najbolje alternative.

SUMMARY

The focus of this paper is a multi-criteria analysis of the situation of Croatian counties. The research was conducted on a dana base that was available on official websites. The time horizon is 2013 to 2015 year.

The PROMETHEE method was applied, starting with the vector-specific method to obtain the weight of criteria required for the analysis process itself in the Decision Lab program package. The analysis was conducted for each of the 21 counties for all 14 criteria, divided into three groups according to the author's decision.

The PROMETHEE II output data point to a wide differences of counties in the economic and territorial area. Choosing the best alternative of this method is the City of Zagreb.

KEY WORDS: multicriteria analysis, PROMETHEE method, counties, choice of best alternatives.