Upotreba GIS-a u planiranju poljoprivredne proizvodnje – uzgoj lijeske

Deak, Marijan

Master's thesis / Diplomski rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of agriculture / Sveučilište Josip Jurja Strossmayera u Osijeku, Poljoprivredni fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:151:021511

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Sveučilište Josipa Jurja Strossmayera u Osijeku
Fakultet agrobiotehničkih znanosti Osijek

Repository / Repozitorij:

Repository of the Faculty of Agrobiotechnical Sciences Osijek - Repository of the Faculty of Agrobiotechnical Sciences Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
POLJOPRIVREDNI FAKULTET U OSIJEKU

Marijan Deak, apsolvent
Diplomski studij Mehanizacije

UPOTREBA GIS-A U PLANIRANJU POLJOPRIVREDNE PROIZVODNJE – UZGOJ LIJESKE

Diplomski rad

Osijek, 2017.

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA
POLJOPRIVREDNI FAKULTET U OSIJEKU

Marijan Deak, apsolvent
Diplomski studij Mehanizacije

UPOTREBA GIS-A U PLANIRANJU POLJOPRIVREDNE PROIZVODNJE – UZGOJ LIJESKE

Diplomski rad

Povjerenstvo za ocjenu i obranu diplomskog rada:

1. prof.dr.sc. Mladen Jurišić, predsjednik
2. doc.dr.sc. Ivan Plaščak, mentor
3. Željko Barač. mag.ing.agr., član

Osijek, 2017.

SADRŽAJ

1. UVOD 1

2. PREGLED LITERATURE 4

2.1. Primjena multikriterijalne analize u svijetu 6

2.2. Primjena multikriterijalne analize u Hrvatskoj 12

3. MATERIJAL I METODE 18

3.1. Postupak multikriterijalne analize 18

3.1.1. Definiranje predmeta analize 18

3.1.2. Određivanje kriterija (faktora i ograničenja) 18

3.1.3. Standardizacija vrijednosti kriterija 20

3.1.4. Određivanje težina faktora 21

3.1.5. Izračun rezultata 22

3.1.6. Analiza rezultata i ocjena točnosti 24

3.2. GIS programi za multikriterijalnu analizu prostornih podataka 24

3.2.1. Slobodni GIS programi 25

3.2.2. Komercijalni GIS programi 26

4. REZULTATI I RASPRAVA 27

4.1. Lijeska 27

4.1.1. Karakteristike lijeske 27

4.1.2. Uzgoj lijeske 29

4.1.3. Stanište lijeske 30

4.2. Vukovarsko-srijemska županija 30

4.2.1. Poljoprivreda i tlo 31

4.2.2. Klima 31

4.3. Multikriterijalna analiza pogodnosti uzgoja lijeske na području Vukovarsko-srijemske županije 32

4.3.1. Priprema podataka za multikriterijalnu analizu 33

4.3.2. Primjer multikriterijalne analize (visoka brzina, niska pouzdanost) 36

4.3.3. Primjer multikriterijalne analize (srednja brzina, srednja pouzdanost) 38

4.3.4. Primjer multikriterijalne analize (niska brzina, visoka pouzdanost) 40

4.3.5. Dodatne analize pomoću dobivenih rezultata pogodnosti multikriterijalnom analizom 45

5. ZAKLJUČAK 49

POPIS LITERATURE **51**

SAŽETAK **53**

SUMMARY **53**

PRILOZI **54**

Prilog A: Kartografski prikazi obilježja Vukovarsko-srijemske županije 54
Prilog B: Prikazi vrijednosti faktora prije i poslije standardizacije (prvi primjer) 56
Prilog C: Elementi korišteni u objedinjavanju podataka (prvi primjer) 59
Prilog D: Prikazi vrijednosti faktora prije i poslije standardizacije (drugi primjer) 60
Prilog E: Elementi korišteni u objedinjavanju podataka (drugi primjer) 63
Prilog F: Prikazi vrijednosti faktora prije i poslije standardizacije (treći primjer) 64
Prilog G: Elementi korišteni u objedinjavanju podataka (treći primjer) 67

POPIS TABLICA **68**

POPIS SLIKA **69**

TEMELJNA DOKUMENTACIJSKA KARTICA **73**

BASIC DOCUMENTATION CARD **74**

1. UVOD

Cilj poljoprivredne proizvodnje u današnje vrijeme je proizvesti što kvalitetniji proizvod u što većim količinama, istovremeno uz minimalne troškove. Razvojem tehnologije i znanosti pojavile su se brojne nove mogućnosti u poljoprivrednoj proizvodnji, kao što su različiti načini uzgoja poljoprivrednih kultura, odabir različitih sorata određene kulture, tretiranje i prihrana biljaka te korištenje različite opreme. Takve mogućnosti su znatno veće u odnosu na one u prošlosti, pa tako sada i za najjednostavnije projekte i investicije postoje brojne varijante korisniku na izbor. Prilikom poljoprivredne proizvodnje vrlo je važna i ekonomska stabilnost proizvodnje, a sve se više pažnje pridaje i utjecaju na okoliš te ekonomičnosti korištenja energije i goriva.

Obzirom na velik broj spomenutih čimbenika u poljoprivrednoj proizvodnji danas, poljoprivrednicima se može dogoditi da povremeno „izgube korak“, u vidu slabije iskorištenosti vremena i novca.

Takvi problemi mogu se riješiti primjenom multikriterijalne analize kao oslonca u donošenju odluka, pogotovo ako korisnik raspolaže s ograničenim sredstvima ili ako ima na raspolaganju velik broj mogućnosti u poljoprivrednoj proizvodnji. Kroz proces multikriterijalne analize i prethodno provedenim istraživanjem o predmetu analize stvara se mogućnost modeliranja utjecaja na pojedini segment poljoprivredne proizvodnje, ali ne samo zasebno nego i kao cjelina. Na taj način se daje rješenje koje predstavlja najoptimalnije moguće iskorištavanje prirodnih i materijalnih resursa koje korisnik ima na raspolaganju. Temeljito planiranje s resursima koje korisnik ima u rukama daje mu realnu mogućnost da proizvede brže i kvalitetnije te zaradi više nego u situaciji da ima ogromne resurse na raspolaganju, ali ih ne iskoristi na ekonomičan način.

Multikriterijalna analiza općenito služi kao potpora u donošenju odluke na temelju više različitih kriterija. Prilikom računanja rješenja, multikriterijalna analiza omogućava rukovanje s vrijednostima kriterija i njihovim pojedinačnim utjecajem na konačni rezultat dodjeljivanjem težina za svaki kriterij. Osim najboljeg mogućeg rješenja, moguće je odrediti i alternativna rješenja, poredana po pogodnosti kojom zadovoljavaju dane kriterije (GIS People (2017)).

Primjena multikriterijalne analize u poljoprivredi moguća je na više različitih načina, primjerice kao što je odlučivanje o kupnji najisplativijeg dijela opreme ili odabira sorte neke poljoprivredne kulture između nekoliko mogućih varijanti. Međutim, zbog naravi poljoprivrede koja je usko povezana s prostorom, mnoge se odluke u poljoprivrednoj proizvodnji tiču prostora i prirodnih uvjeta na tom prostoru. Poljoprivredno zemljište je nepomična komponenta u poljoprivrednoj proizvodnji i na brojne čimbenike na zemljištu se ne može utjecati (reljef, klima i sl.). S druge strane, ono na što poljoprivrednik može utjecati je način kako će i kada obrađivati tlo tog poljoprivrednog zemljišta kako bi najbolje moguće iskoristio njegov potencijal. Odgovore na takva pitanja, koja su u bilo kakvom odnosu s prostorom, omogućava multikriterijalna analiza prostornih podataka.

Prostorni podaci su sve do nedavno bili dostupni samo u obliku analognih karata, što je uvelike ograničavalo korisnike u njihovoj interpretaciji, a pogotovo pri planiranju te integraciji s ostalim vrstama podataka i prostornim podacima druge tematike. Razvojem računala i digitalne obrade podataka ti su problemi riješeni, a također je olakšana izrada i razmjena prostornih podataka u raznim formatima. U domeni digitalne obrade prostornih podataka, koristi se geografski informacijski sustav (eng. *Geographic Information System*, GIS), koji omogućuje integraciju gotovo svih vrsta prostornih podataka te raznoliku obradu i analizu tih podataka.

Geografski informacijski sustav je sustav za upravljanje prostornim podacima i osobinama pridruženih njima. U najstrožem smislu to je računalni sustav sposoban za integriranje, spremanje, uređivanje, analiziranje i prikazivanje geografskih informacija. (FMLC (2017))

Tehnologija geografskog informacijskog sustava može se koristiti za znanstvena istraživanja, upravljanje resursima, imovinsko upravljanje, planiranje razvoja, kartografiju i planiranje puta. Svaka varijabla koja se može prostorno smjestiti može se pohraniti u GIS-u. GIS podaci predstavljaju objekte u stvarnom svijetu (ceste, uporabu zemljišta, visinu, …) pomoću digitalnih podataka. Objekti u stvarnom svijetu mogu se podijeliti u dvije apstrakcije: zasebni objekti (npr. kuće) i neprekinuta polja (npr. količina oborina ili visina). Za obje apstrakcije postoje dvije široke metode korištene u spremanju podataka u GIS-u: rasterska i vektorska metoda. Tip rasterskih podataka sastoji se od redova i stupaca ćelija

gdje se u svakoj ćeliji sprema pojedinačna vrijednost. Vrlo često su rasterski podaci slike (rasterske slike). Tip vektorskih podataka za prikaz objekata koristi geometriju poput točaka, linija (serije točkastih koordinata) ili poligona, također zvanih područjima (oblici omeđeni linijama). (FMLC (2017))

Specifičnost GIS-a je rad sa slojevima, čime se vizualiziraju rasterski i vektorski podaci. Oni se mogu predstaviti kao klasični planovi nacrtani na prozirnim folijama, pri čemu svaka folija sadrži samo određene vrste informacija (putovi, vode, zgrade i ostalo) (Jurišić i Plaščak, 2009.). Također je moguć rad s gotovo svim koordinatnim referentnim sustavima u svijetu, odnosno transformacije podataka između dva referentna sustava.

Multikriterijalna analiza prostornih podataka tako predstavlja skup radnji kojima se omogućava maksimalno iskorištavanje dostupnih podataka o prostoru u GIS okruženju u svrhu donošenja najkvalitetnije moguće odluke. Cilj ovog rada je koristeći metodu prostornog višekriterijskog odlučivanja (primjena višekriterijske analize u prostornom kontekstu gdje alternative, kriteriji i drugi elementi postojećeg problema imaju eksplicitne prostorne dimenzije) prikazat će se mogućnost izrade tematske karte pogodnosti uzgoja lijeske u različitim dijelovima Vukovarsko-srijemske županije.

2. PREGLED LITERATURE

Općenito je cilj multikriterijalne analize pronaći najpogodnije područje u skladu s postavljenim kriterijima, a što se poljoprivrede tiče to se može odnositi na nekoliko segmenata. Jedan od njih je traženje najpogodnijeg mogućeg područja za uzgoj neke kulture, ukoliko se pojedinac odluči na kupovinu zemljišta i uspostavljanje ili širenje poljoprivredne proizvodnje. Takve investicije uglavnom su vrlo velikog iznosa, pa čak i najmanja korisna informacija može donijeti osjetnu korist u povećanju kvalitete i količine uroda te smanjenju troškova u takvoj situaciji. U tom slučaju multikriterijalnom analizom bi se na temelju poznavanja kriterija koji opisuju učinke na rast određene kulture te ekonomskih i infrastrukturnih kriterija od interesa za pojedinca moglo uvelike pomoći pri odlučivanju oko određivanja područja na kojem će se uspostaviti nasadi.

Slična primjena bila bi u cilju boljeg gospodarenja zemljištem pojedinca ili tvrtke koji raspolažu većim brojem poljoprivrednih čestica, kako bi se pomoglo u odlučivanju gdje će se i kada posaditi/posijati određeni usjevi, a da se istovremeno meteorološki i pedološki uvjeti te ostali resursi iskoriste na najbolji mogući način. Tada bi se multikriterijalna analiza provodila izračunavanjem pogodnosti za određenu kulturu i preklopom vrijednosti piksela koji označavaju pogodnost s vektorskim slojem poljoprivrednih čestica u posjedu te rangiranjem čestica, a ne piksela po pogodnosti.

Još jedna mogućnost je procjena količine usjeva u vrijeme kada su usjevi u ranom stadiju rasta na temelju vegetacijskih i ostalih spektralnih indeksa iz podataka daljinskih istraživanja i podataka o kvaliteti zemlje i obavljenoj gnojidbi. Ovakav pristup ima potencijal korištenja i potpore u povećanju kvalitete poljoprivredne proizvodnje tijekom dužeg vremenskog razdoblja, uspoređivanjem ranih predviđanja količine usjeva sa stvarnom količinom usjeva nakon sjetve i uočavanja korelacije između tih podataka i provođenja korekcija u modelu predviđanja.

Multikriterijalna analiza može se koristiti i kod prevencije razine štete uslijed vremenskih neprilika, određivanjem najrizičnijih područja ovisno o tipu vremenskih neprilika (poplava, oluja, tuča, …) i načina na koji te vremenske prilike djeluju na reljef, tlo i usjeve. Rano otkrivanje rizika daje mogućnost poljoprivredniku da na vrijeme zaštiti svoje usjeve ili na neki drugi način umanji potencijalnu štetu od vremenskih neprilika.

Kriteriji koji se mogu koristiti u multikriterijalnoj analizi vezanoj uz poljoprivredu su brojni, a neki od njih mogu biti kriteriji:

1. Reljefa:
    - nadmorska visina terena,
    - nagib i ekspozicija terena,
    - insolacija (količina upadne svjetlosti),
    - izloženost vjetru i
    - utjecaj padalina na teren.
2. Infrastrukturni:
    - udaljenost naselja,
    - udaljenost cesta i
    - dostupnost vodovodne i elektroenergetske mreže.
3. Pedološki:
    - vrsta tla,
    - dubina tla,
    - obradivost tla,
    - pH vrijednost tla i
    - temperatura i vlažnost tla.
4. Meteorološki:
    - prosječna količina padalina,
    - prosječna temperatura i
    - ekstremi količine padalina i temperature ovisno o dobu godine.
5. Ekonomski:
    - cijena poljoprivrednog zemljišta,
    - cijena uspostavljanja i održavanja nasada i
    - nameti ovisno o jedinici regionalne/lokalne samouprave.
6. Administrativni:
    - pogodna područja u skladu s prostornim planovima uređenja i
    - područja koja ne spadaju pod opće ili javno dobro.
7. Ostali

2.1. Primjena multikriterijalne analize u svijetu

Primjena multikriterijalne analize pogotovo je korisna za siromašne zemlje i zemlje u razvoju, kako bi maksimalno iskoristile ograničene prirodne i novčane resurse te time podigli kvalitetu poljoprivredne proizvodnje. Iako je primjena multikriterijalne analize prisutna i u razvijenijim zemljama, sudeći prema broju stručnih članaka o toj temi, trenutno je dominantna primjena baš u spomenutim siromašnijim državama.

Analiza istraživanja i primjena multikriterijalne analize provedena je kroz 7 teoretskih koraka multikriterijalne analize, s naglaskom na cilj analize, odnosno njezinu specifičnost i primjenjivost u poljoprivredi. Posebna pažnja je posvećena načinu dodjeljivanja težina faktorima, obzirom da je to korak multikriterijalne analize u kojem korisnik ima najveći utjecaj na konačni rezultat.

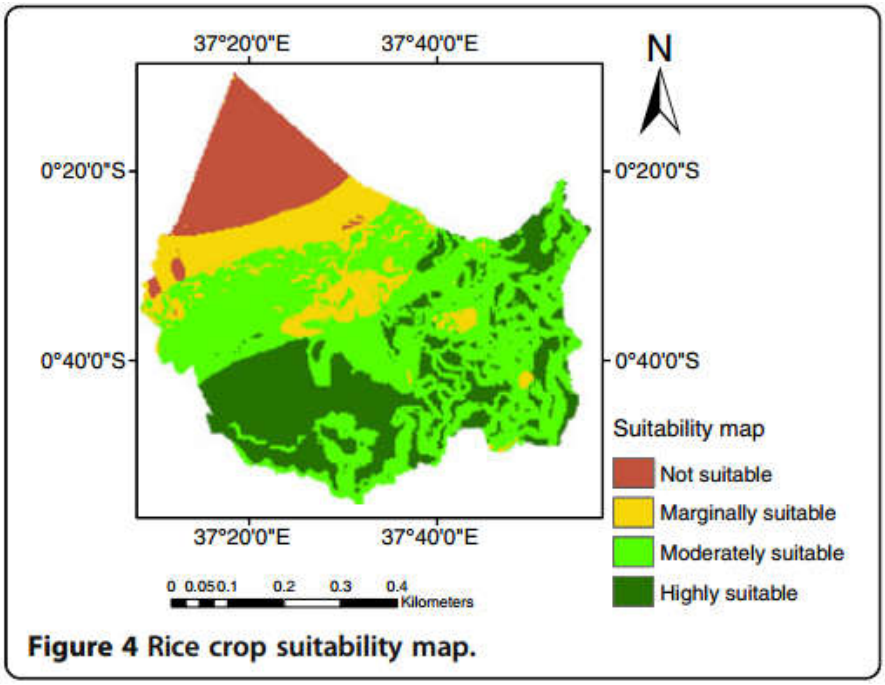
Kihoro i sur. (2013) proveli su studiju s ciljem kreiranja karte pogodnosti za uzgoj riže temeljen poznatih fizičkih (biofizičke značajke tla i topografske značajke) i klimatskih faktora korištenjem multikriterijalne analize u GIS okruženju. Studija je provedena u Keniji, obuhvaćajući područje tri različite pokrajine (Kirinyaga, Embu i Mberee). Riža postaje glavna kultura i od vrlo visoke važnosti je za cijelo područje južno od Sahare, obzirom na nagli porast broja stanovnika na tom području i urbanizaciju. Prilikom obrade podataka korišten je program ArcGIS.

U spomenutoj analizi je korišteno 6 kriterija (faktora): vlažnost tla, temperatura, tekstura tla, pH vrijednost tla, stupanj isušivanja tla i nagib terena. Standardizacija vrijednosti faktora provedena je metodom klasiranja u 7 klasa, označavanjem vrlo niske, niske, umjereno niske, umjerene, umjereno visoke, visoke i vrlo visoke pogodnosti faktora na uzgoj riže. Za određivanje težina faktora korištena je matrica usporedbe parova, sa skalom usporedbe faktora u intervalu od 1 do 7. Uvjerljivo najveća težina pridružena je faktoru temperature zraka (0,41) (slika 1.). Standardizirane vrijednosti faktora i njihove težine objedinjeni su metodom težinske linearne kombinacije.

Scale	Topography	Humidity	Temperature	Soil PH	Soil texture	Soil drainage	Weights	Ranking
Topography	1	7	1/3	5	1/3	3	0.1843	3
Humidity	1/7	1	1/5	1/3	1/5	1/5	0.0355	6
Temperature	3	5	1	7	5	5	0.4153	1
Soil PH	1/5	3	1/7	1	1/5	1/ 5	0.0497	5
Soil texture	3	5	1/5	5	1	1	0.1865	2
Soil drainage	1/3	5	1	5	1	1	0.1287	4
CR = 0.08							∑ = 1	

Slika 1. Težine faktora pri određivanju pogodnosti područja za uzgoj riže na području pokrajina Kirinyaga, Embu i Mberee u Keniji (Kihoro i sur., 2013.)

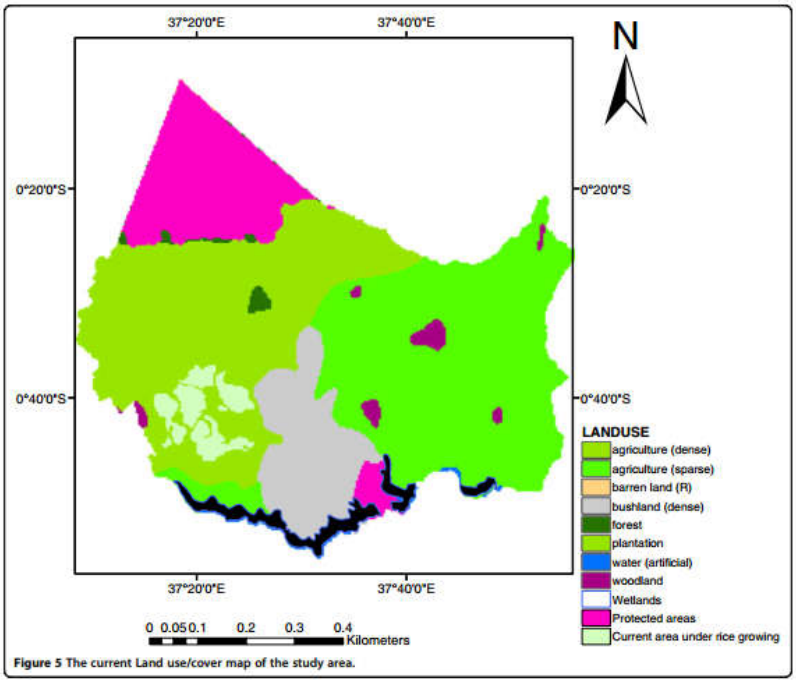
Konačne vrijendosti pogodnosti reklasificirane su u četiri klase, koje označavaju visoko pogodno (eng. *highly suitable*), umjereno pogodno (eng. *moderately suitable*), granično pogodno (eng. *marginally suitable*) i nepogodno područje (eng. *not suitable*) (slika 2.). Visoko pogodno područje pokriva 105 769 ha, odnosno 24,69% ukupnog područja od interesa, a karakteriziraju ga niski nagib terena, pH vrijednost tla u rasponu od 5,6 do 7,3; glinena tla, visoka vlažnost tla i umjerene temperature zraka. Najprisutnija klasa je umjereno pogodno područje s 47,45% ukupnog područja. Nepogodna područja su uglavnom planinska područja s nagibom terena većim od 50%.



Slika 2. Karta pogodnosti područja za uzgoj riže na području pokrajina Kirinyaga, Embu i Mberee u Keniji (Kihoro i sur., 2013.)

Dodatna analiza provedena je temeljem izrade karte pokrova zemljišta za područje od interesa (slika 3.), iz koje je izračunato da je u trenutku izrade studije rižom bilo zasijano 13 369 ha. Podaci pogodnosti za uzgoj riže (potencijalno zemljište za uzgoj) i podaci trenutnog

pokrova zemljišta su potom preklopljeni, iz čega su izvučeni zaključci da je 75% tadašnjih nasada riže bilo na područjima visoke pogodnosti, a 25% na područjima umjerene pogodnosti za uzgoj riže. Također je uočeno da je vrlo malen dio (12%) od čak 105769 ha visoko pogodnog područja za uzgoj riže bio iskorišten za proizvodnju riže (spomenutih 13369 ha).



Slika 3. Karta pokrova zemljišta na području pokrajina Kirinyaga, Embu i Mberee u Keniji (Kihoro i sur., 2013.)

Sarkar i sur. (2012) ističu važnost multikriterijalne analize u kombinaciji s GIS-om za procjenu prikladnosti uporabe zemljišta (eng. *land suitability*), navodeći kako neodgovarajući način uporabe zemljišta rezultira degradacijom kvalitete tla i smanjenom učinkovitosti poljoprivredne proizvodnje. U studiji koju su izradili, analizira se pogodnost zemljišta za uzgoj pšenice u porječju Beko u Indiji. Spomenuto zemljište općenito je umjereno pogodno za rast pšenice, uz prisutna ograničenja kao što su neujednačen sustav odvodnje i neodgovarajuća dubina tla.

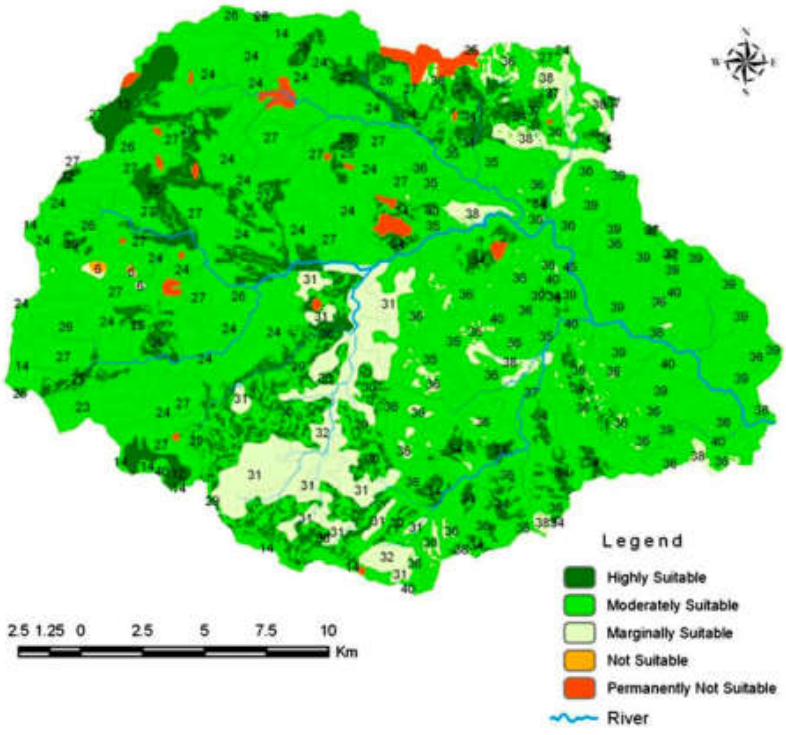
Prilikom multikriterijalne analize korišteno je 7 kriterija (faktora), koji opisuju karakteristike tla (dubina tla, tekstura tla, propusnost tla i pH vrijednost), klime (količina padalina), reljefa (nagib terena) i pokrov zemljišta. Vrijednosti faktora standardizirane su metodom klasiranja u 5 klasa: S1 (visoka pogodnost), S2 (umjerena pogodnost), S3 (marginalna pogodnost), N1 (trenutna nepogodnost) i N2 (trajna nepogodnost), kojima su

potom pridružene vrijednosti od 1 za najmanju pogodnost do 5 za najveću pogodnost. Težine faktora određene su metodom matrice usporedbe parova sa skalom relativne važnosti, odnosno usporedbe faktora, u intervalu od 1 do 9. Najveće težine dane su karakteristikama tla: dubini tla (0,31), propusnosti tla (0,25) i teksturi tla (0,18) (slika 4.). Tako određene vrijednosti objedinjene su metodom težinske linearne kombinacije.

Factors	Depth	Drainage	Texture	Slope	Rainfall	pH	LULC	Priority vector or weight	% of weight
Depth	0.3477	0.4570	0.3238	0.2941	0.2970	0.2459	0.2121	0.3111	31
Drainage	0.1738	0.2285	0.3238	0.2941	0.2970	0.2459	0.2121	0.2536	25
Texture	0.1738	0.1143	0.1619	0.1961	0.1782	0.2459	0.2121	0.1832	18
Slope	0.1159	0.0762	0.0810	0.0980	0.1188	0.0984	0.1515	0.1057	11
Rainfall	0.0695	0.0457	0.0540	0.0490	0.0594	0.0984	0.0909	0.0667	7
pH	0.0695	0.0457	0.0324	0.0490	0.0297	0.0492	0.0909	0.0523	5
LULC	0.0497	0.0326	0.0231	0.0196	0.0198	0.0164	0.0303	0.0274	3

Slika 4. Raspodjela težina pri određivanju pogodnosti za uzgoj pšenice u porječju Beko u Indiji (Sarkar i sur., 2012.)

Konačne vrijednosti pogodnosti područja za uzgoj pšenice u porječju Beko klasificirane su na isti način kao i prilikom standardizacije. Sa slike 5. vidljivo je da prevladava umjereno pogodno područje za uzgoj pšenice, kao što je prvotno bilo i pretpostavljeno, pokrivajući gotovo 76% ukupnog područja. Slijede visoko pogodno područje (12%) i marginalno pogodno područje (10,5%), dok nepogodna područja zauzimaju vrlo malen udjel u rezultatu.



Slika 5. Karta područja pogodnosti za uzgoj pšenice u porječju Beko u Indiji (Sarkar i sur., 2012.)

Temeljem dobivenih rezultata, autori iskazuju potencijal ovakvog pristupa za više različitih usjeva, kao i nadogradnju multikriterijalne analize u poljoprivredi uvođenjem socio-ekonomskih kriterija i kriterija povezanih s okolišem.

Singha i Swain (2016.) u studiji kriterija za izbor prikladnosti uporabe zemljišta u poljoprivredi također označavaju važnost prikladne uporabe zemljišta prilikom odlučivanja o sjetvi usjeva, upravljanju poljoprivrednim zemljištem i sličnim aktivnostima. Studija je provedena kao sažetak članaka o multikriterijalnoj analizi prostornih podataka u poljoprivredi te različitosti metoda primijenjenih u njima. Opisuju kombinaciju multikriterijalne analize te GIS-a i daljinskih istraživanja kao alate za ostvarivanje bolje poljoprivredne proizvodnje, a *fuzzy* metode u multikriterijalnoj analizi navode kao najpogodnije za poljoprivredu.

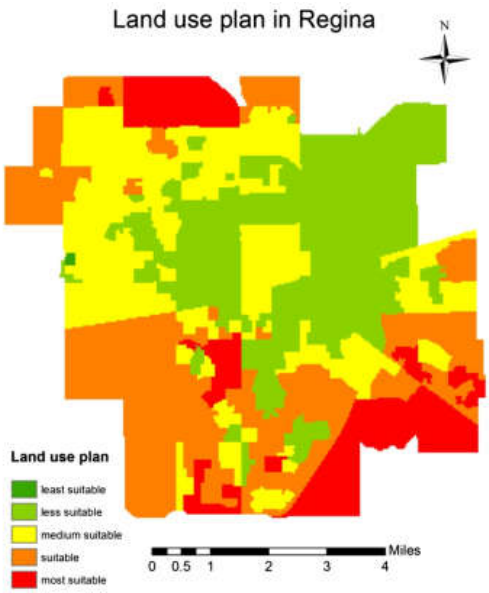
Chen (2014.) proveo je studiju procjene prikladnosti uporabe zemljišta na urbanom području grada Regina i njegove okolice u Kanadi temeljem multikriterijalne analize prostornih podataka. Termin prikladnosti uporabe zemljišta u ovoj studiji odnosi se na veću pogodnost za stambene i komercijalne objekte. Obzirom na područje analize koje je pretežno naseljeno, unutar multikriterijalne analize korišteni su socio-ekonomski kriteriji (faktori), odnosno gustoća naseljenosti, gustoća zaposlenih osoba i prosječni prihod po dijelovima grada. Program korišten za obradu podataka je ArcGIS.

Sam postupak multikriterijalne analize proveden je na vrlo jednostavan način. Vrijednosti faktora su standardizirane metodom klasiranja u 5 klasa, a težine su dodijeljene faktorima bez neke specifične metode na način prikazan na slici 6. Takav postupak predstavlja dobar primjer kako je multikriterijalna analiza prvenstveno subjektivan postupak i kako postojeće metode za svaki korak multikriterijalne analize korisniku mogu biti samo na pomoć, a ne ga obvezivati i sputavati. Standardizirane vrijednosti faktora i njihove težine objedinjeni su metodom težinske linearne kombinacije.

Criteria	Wj
Population	10
Employment	6
Average_income	4

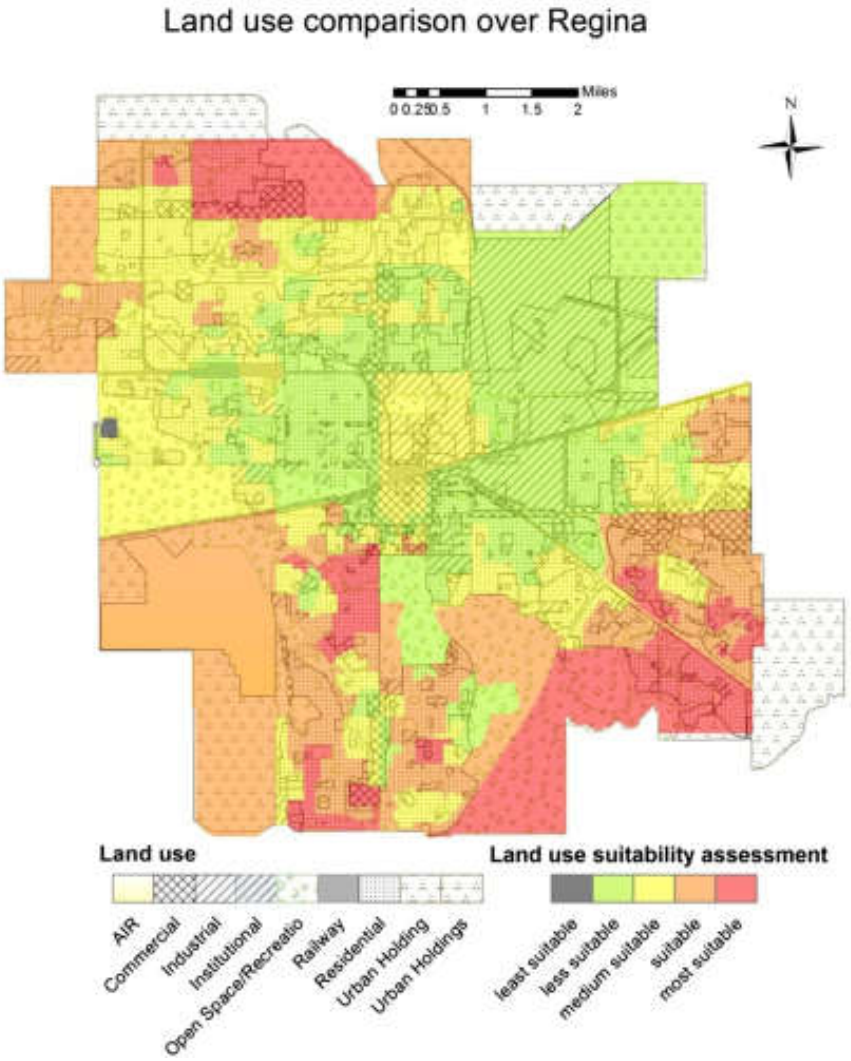
Slika 6. Raspodjela težina pri određivanju prikladnosti uporabe zemljišta na području grada Regina u Kanadi (Chen, 2014.)

Rezultat je klasificiran u 5 klasa pogodnosti (slika 7.), koje označavaju najpogodnije, pogodno, srednje pogodno, manje pogodno i najmanje pogodno područje u skladu s postavljenim kriterijima. Najpogodnija područja označena su crveno, a kao što je ranije spomenuto, predstavljaju najveću pogodnost za komercijalne aktivnosti i stanovanje.



Slika 7. Karta prikladnosti uporabe zemljišta na području grada Regina u Kanadi (Chen, 2014.)

Kao temelj za vizualnu analizu rezultata multikriterijalne analize i procjene kvalitete upotrebe zemljišta u stvarnosti izrađen je kartografski prikaz (slika 8.) dobiven preklapanjem karte prikladnosti uporabe zemljišta iz analize (obojano) i karte stvarnog načina uporabe zemljišta (šrafirano). Iz tog prikaza zaključeno je da analizirano i stvarno stanje dosta odudaraju jedno od drugog.



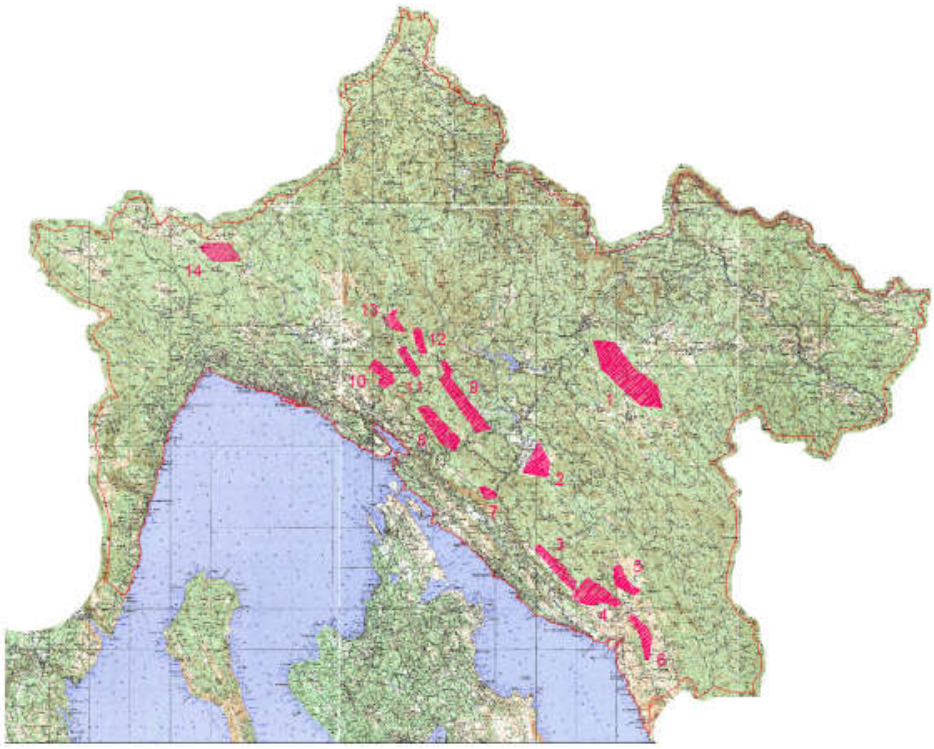
Slika 8. Usporedba prikladnosti uporabe zemljišta na području grada Regina u Kanadi (Chen, 2014.)

2.2. Primjena multikriterijalne analize u Hrvatskoj

Prilikom istraživanja i traženja primjena multikriterijalne analize u Hrvatskoj, nisu pronađene studije s primjenom u poljoprivredi, a područja primjene većinom pokrivaju obalno i priobalno područje Hrvatske. Metode korištene u tim studijama relativno su jednostavne u odnosu na one u svijetu i znatno je veći subjektivan utjecaj korisnika na rezultat.

Energetski institut Hrvoje Požar proveo je analizu prostornih mogućnosti za korištenje energije vjetra u Primorsko-goranskoj županiji 2009. godine (Zavod za prostorno uređenje Primorsko-goranske županije (2017)). Prije izvršavanja multikriterijalne analize za određivanje područja najpogodnijih za gradnju vjetroelektrane određeno je 14 potencijalnih

lokacija, namijenjenih za kasnije rangiranje po zadovoljavanju postavljenih kriterija (slika 9.).



Slika 9. Potencijalne lokacije za gradnju vjetroelektrane u Primorsko-goranskoj županiji u studiji iz 2009. godine

Izvor: Zavod za prostorno uređenje Primorsko-goranske županije (2017)

Za analizu je odabrano 10 kriterija (faktora), podijeljenih u tri tematske skupine: topografsko-klimatološke kriterije (vjetropotencijal, proizvodnost, prihvatni kapacitet lokacije, hrapavost površine i vegetacija), tehničko-infrastrukturne kriterije (udaljenost priključka, ekspertna ocjena mogućnosti prihvata obzirom na stanje mreže, pristupni put) te prostorno-planske i okolišne elemente (udaljenost naselja, blizina zaštićenih područja, namjena prostora i kvalitativna procjena vrijednosti zemljišta). Faktori su standardizirani unutar brojčanog intervala od 0 do 4 metodom klasiranja u 5 klasa. Vrijednosti su u pravilu dodjeljivane redom klasama na način (0,1,2,3,4), ali su vrijednosti jednog faktora određene na način (0,0, 1,8, 2,4, 3,2, 4,0), što pokazuje subjektivno odstupanje od pravila i omogućava korisniku veću slobodu pri standardizaciji vrijednosti faktora. Težine faktora su određene unutar intervala 0-1, no njihov zbroj ne poprima vrijednost 1, što ponovno predstavlja subjektivno odstupanje od metode procjene (slika 10.). Standardizirane vrijednosti faktora i težine objedinjeni su metodom težinske linearne kombinacije (slika 11.).

Kriterij		Težinski faktor
Topografsko-klimatološki elementi lokacije		
1a	vjetropotencijal na 80 m iznad tla	1
1b	proizvodnost	1
1c	prihvatni kapacitet lokacije	0,4
1d	hrapavost površine i vegetacija	0,5
Tehničko-infrastrukturni elementi		
2a	udaljenost priključka na EES	0,6
2b	ekspertna ocjena mogućnosti prihvata obzirom na stanje mreže	0,8
2c	pristupni put	0,3
Prostorno-planski i okolišni elementi		
3a	udaljenost naselja	0,4
3b	blizina zaštićenih područja, EM, SPA područja	0,7
3c	namjena prostora i kvalitativna procjena vrijednosti zemljišta	0,3

Slika 10. Težine faktora pri multikriterijalnoj analizi određivanja pogodnosti za gradnju vjetroelektrane u Primorsko-goranskoj županiji u studiji iz 2009. godine

Izvor: Zavod za prostorno uređenje Primorsko-goranske županije (2017)

Lokacija	Kriterij 1	Kriterij 2	Kriterij 3	Kriterij 4	Kriterij 5	Kriterij 6	Kriterij 7	Kriterij 8	Kriterij 9	Kriterij 10	
	brzina vjetra	proizvodnost	kapacitet	hrapavost površine	udaljenost priključka	prihvat	pristup	namjena prostora	zaštita prirode	blizina naselja	Težinska suma
	1,0	1,0	0,4	0,5	0,6	0,8	0,3	0,4	0,7	0,3	
Poljička kosa	2.4	2	4	1	4	3	2	3.025	1.600	0.4	14.4
Fužine	1.8	1	2	3.5	3	3	4	3.550	2.400	0.8	14.1
Kavranica	1.8	1	2	3	4	1	3	3.780	2.600	0.98	12.8
Novi Vinodolski	2.4	2	3	2	4	1	3	3.050	2.400	0.85	13.9
Breza	2.4	2	2	4	2	1	4	3.910	3.200	1.6	14.7
Vršci	3.2	4	2	3	3	1	3	3.025	3.600	1.275	17.1
Zebar	4	4	1	3.5	2	3	4	4.000	2.400	2.23	18.9
Peškovo	3.2	3	2	2.5	3	4	3	3.550	3.200	0.53	18.0
Tuhobić	4	4	3	1	3	4	1	2.750	2.200	1.7	18.2
Osoje	2.4	1	1	2	0	4	3	2.400	3.200	0.08	12.1
Jelenje	2.4	2	1	2	0	4	4	3.910	3.000	4	15.1
Pliš	3.2	4	1	3	0	4	1	3.780	3.000	4	17.4
Platak	2.4	2	1	2	0	4	3	3.15	2.8	4	14.3
Lipa	0	0	2	3	2	1	4	2.550	2.600	1.4	8.8

Slika 11. Pogodnosti idejnih lokacija za gradnju vjetroelektrane u Primorsko-goranskoj županiji u studiji iz 2009. godine

Izvor: Zavod za prostorno uređenje Primorsko-goranske županije (2017)

Obzirom na odabir idejnih lokacija prije izvođenja multikriterijalne analize, one su rangirane po vrijednosti pogodnosti za izgradnju vjetroelektrane (slika 12.). Tako je određeno najpogodnije područje (lokacija Zebar) te njegove alternative, u slučaju da je neki utjecaj u analizi pogrešno modeliran ili na terenu iz nekog razloga nije moguće na najboljoj lokaciji ostvariti gradnju vjetroelektrane.

Lokacija	Konačna ocjena	Rang
Zebar	18.9	1
Tuhobić	18.2	2
Peškovo	18.0	3
Pliš	17.4	4
Vršci	17.1	5
Jelenje	15.1	6
Breza	14.7	7
Poljička kosa	14.4	8
Platak	14.3	9
Fužine	14.1	10
Novi Vinodolski	13.9	11
Kavranica	12.8	12
Osoje	12.1	13
Lipa	8.8	14

Slika 12. Rangiranje idejnih lokacija za gradnju vjetroelektrane u Primorsko-goranskoj županiji u studiji iz 2009. godine

Izvor: Zavod za prostorno uređenje Primorsko-goranske županije (2017)

Dodatnom analizom sveobuhvatnih ekoloških i prostornih utjecaja na idejnim lokacijama doneseni su zaključci, primjerice da je lokacija Zebar (slika 13.) smještena na području u prostornom planu definiranom kao ostalo poljoprivredno tlo, šume i šumsko zemljište, a manjim dijelom zadire u zaštitnu šumu (jugozapadni rub). Za pristup lokaciji ne postoji kategorizirana prometnica te je moguća korist od korištenja energije vjetra izgradnja novog puta niže kategorije za gospodarsko iskorištavanje šuma na rubnom području ove lokacije.

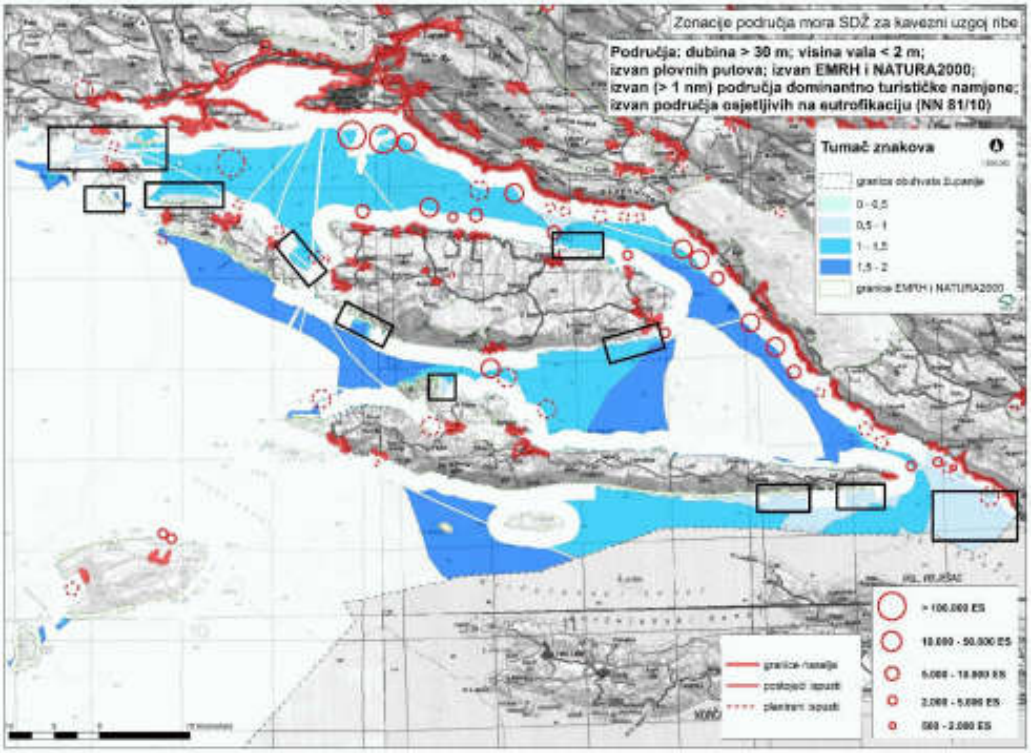


Slika 13. Idejna (najpogodnija) lokacija Zebar za gradnju vjetroelektrane u Primorsko-goranskoj županiji u studiji iz 2009. godine

Izvor: Zavod za prostorno uređenje Primorsko-goranske županije (2017)

Institut za primijenjenu ekologiju OIKON 2012. godine proveo je studiju korištenja i zaštite mora i podmorja na području Splitsko-dalmatinske županije (OIKON (2012)), pri čemu je multikriterijalna analiza korištena za određivanje najpogodnijih lokacija za kavezni uzgoj ribe i uzgoj školjkaša.

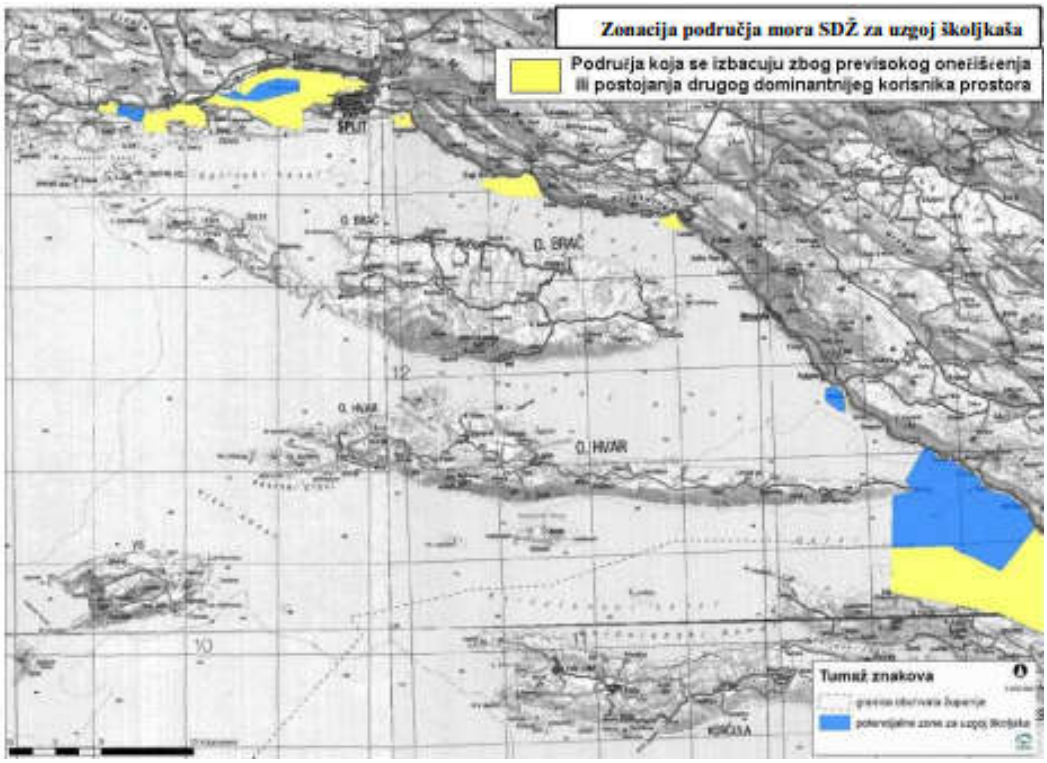
Za kavezni uzgoj ribe (slika 14.) korišteni kriteriji su visina valova ispod 2 m, dubina mora iznad 30 m, područja koja nisu plovni putevi i područja koja nisu dominantno turističke namjene kao ograničenja. Nakon što je područje koje zadovoljava sva četiri postavljena ograničenja izdvojeno, ručno su postavljeni crni pravokutnici koji označavaju površinu potrebnu za sidrenje kaveza na temelju dodatnih kriterija koji nisu usko vezani uz multikriterijalnu analizu.



Slika 14. Područja koja zadovoljavaju postavljena ograničenja za kavezni uzgoj ribe u Splitsko-dalmatinskoj županiji iz studije 2014.

Izvor: OIKON (2012)

Područje za uzgoj školjkaša (slika 15.) određeno je odabirom područja povećane trofičnosti mora, s većom primarnom produkcijom omogućenom donosom hranjivih soli s kopna, koja su zatim reducirana područjima na kojima je prisutno preveliko onečišćenje ili postojanje drugog dominantnijeg korisnika prostora. Izdvojeni poligoni tako su obrađeni zasebno korištenjem dodatnih kriterija, nakon čega su ponovno reducirani. Takav pristup predstavlja vrlo neuniformiran i jednostavan postupak, gdje korisnik ima velik nadzor nad rezultatom, a stupanj automatizacije je znatno umanjen.



Slika 15. Područja koja zadovoljavaju postavljena ograničenja za uzgoj školjkaša u Splitsko-dalmatinskoj županiji iz studije 2014.

Izvor: OIKON (2012)

3. MATERIJAL I METODE

Metode obavljanja multikriterijalne analize i pripadajući materijal podijeljeni su na teoretski dio multikriterijalne analize u koji spada opis metoda za pojedini korak u analizi te opis odgovarajućih GIS programa i njihovih mogućnosti za praktično izvršavanje opisanih metoda.

3.1. Postupak multikriterijalne analize

Postupak izvršavanja multikriterijalne analize moguće je razložiti na sljedeće korake (Estoque, 2011):

1. Definiranje predmeta analize,
2. Određivanje kriterija (faktora i ograničenja),
3. Standardizacija vrijednosti kriterija,
4. Određivanje težine faktora,
5. Izračun rezultata i
6. Analiza rezultata i ocjena točnosti

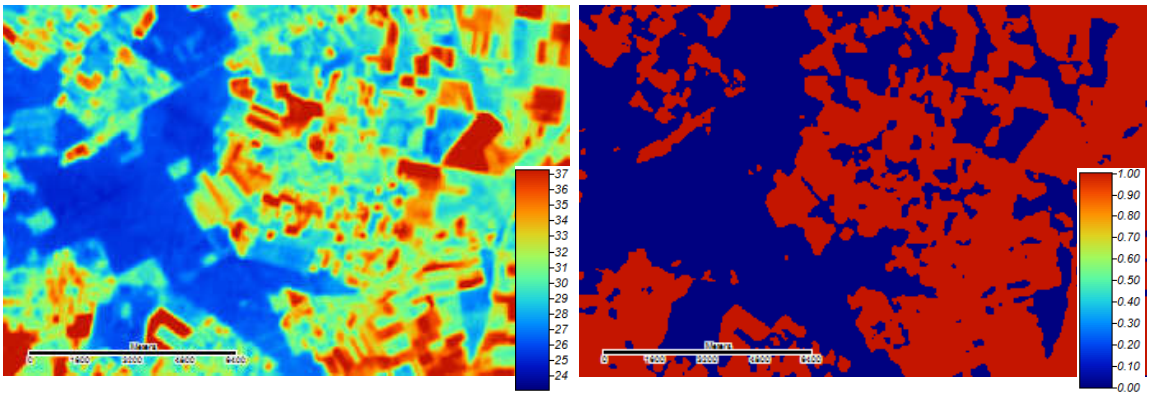
U nastavku je dan opis definiranih koraka multikriterijalne analize i najvažnijih metoda izvršavanja pojedinih koraka.

3.1.1. Definiranje predmeta analize

Preduvjet za postizanje kvalitetne odluke je prethodno definiran i jasan cilj. Također, temeljnim planiranjem i prikupljanjem relevantnih podataka o objektu analize cijeli proces analiziranja i odlučivanja se ubrzava i poboljšava.

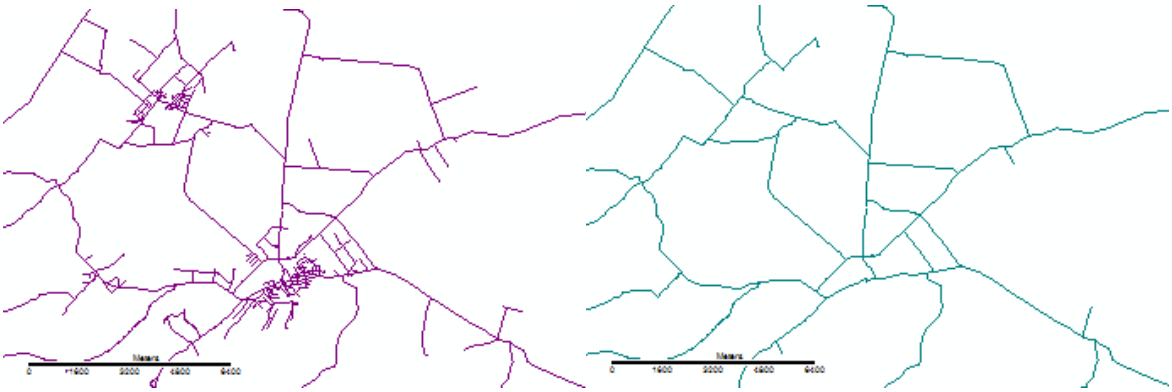
3.1.2. Određivanje kriterija (faktora i ograničenja)

Nakon što su planiranjem i istraživanjem dostupne relevantne znanstvene i stručne literature određeni kriteriji koji utječu na donošenje odluke, odnosno određivanje područja u GIS okruženju, potrebno je kriterije raščlaniti na faktore (eng. *factors*) i ograničenja (eng. *constrains*). Za razliku od ograničenja koja definiraju na kojem području je određeni kriterij isključivo zadovoljen ili ne, faktorima se na kontinuiran način iskazuje razina zadovoljavanja kriterija (slika 16.).



Slika 16. Prikaz temperature terena određene preko Landsat 8 termalnog kanala na dan 26.08.2017. kao faktora (lijevo) i ograničenja s graničnom vrijednosti 30°C (desno)

Ovisno o potrebi analize, provodi se generalizacija i procjena kriterija. Generalizacijom se utječe na detaljnost pojedinog GIS sloja obzirom na svrhu u koju se taj sloj koristi. Primjerice, ukoliko se u multikriterijalnoj analizi koristi kriterij udaljenosti područja od prometnica, potrebno je definirati vrste cesta od kojih će ta udaljenost biti računata. Za kriterij utjecaja ispušnih plinova vozila na rast određene kulture tako je dovoljno obuhvatiti državne, županijske i lokalne ceste, dok bi se uključivanjem sporednih cesta (kao što je makadam) bespotrebno utjecalo na kvalitetu analize, obzirom da su na njima promet i onečišćenje znatno manji (slika 17.). Generalizacija je primjenjiva i na gustoću meteoroloških podataka, podatke uzorkovanja tla, površinsku rezoluciju podataka daljinskih istraživanja i tako dalje. Bitni čimbenici kod generalizacije su vrsta analize i subjektivna procjena korisnika.



Slika 17. Prikaz cesta prije (lijevo) i poslije generalizacije (desno)

Procjena kriterija odnosi se na interpretaciju kriterija kojeg je teško modelirati, a ima značajan utjecaj na rezultat analize. Primjer procjene količine i zdravlja vegetacije tako je moguće dobiti korištenjem normaliziranog vegetacijskog indeksa (eng. *Normalized Difference Vegetation Index*, NDVI) iz podataka daljinskih istraživanja (Rouse i dr, 1973).

Važno je napomenuti da se kriteriji ne moraju nužno dijeliti na faktore i ograničenja, već se multikriterijalna analiza može provesti isključivo s faktorima ili ograničenjima. Ukoliko se radi samo s ograničenjima, tada se ne provodi gotovo cijeli uobičajeni postupak, već se nad rasterskim slojevima ograničenja provodi operacija množenja, a na vektorskima operacija presjeka. Time se direktno dobiva rezultat analize, tako da postoje elementi koji u potpunosti zadovoljavaju ili ne zadovoljavaju postavljene kriterije, bez opcije za izbor alternative. Postupak za samo faktore gotovo je u potpunosti jednak kao i za kombinaciju obje vrste kriterija.

Kada se radi o multikriterijalnoj analizi prostornih podataka, svi kriteriji moraju biti definirani unutar istog referentnog koordinatnog okvira i kartografske projekcije (službeno u Hrvatskoj HTRS96/TM (Lapaine i Tutić, 2007.)), i samim time moraju biti mjerljive veličine.

3.1.3. Standardizacija vrijednosti kriterija

Za sve faktore elementima rasterskog ili vektorskog sloja dodjeljuje se vrijednost koja označava stupanj pogodnosti faktora unutar određenog brojčanog intervala, koji je isti za sve faktore koji sudjeluju u analizi. Postupak kojim se vrijednosti pojedinog sloja svode unutar tog brojčanog intervala naziva se standardizacija (Voogd, 1983.). Pritom veće vrijednosti označavaju veću pogodnost, a manje vrijednosti manju pogodnost određenog faktora na rezultat.

Prema Eastmanu (1999.), najčešći oblik standardizacije podataka je linearno skaliranje između minimalne i maksimalne vrijednosti odabranog brojčanog intervala (npr. 0-1, 0-100, 0-255). Linearno skaliranje izvodi se pomoću formule:

$$X_i = \frac{x_i - min_i}{max_i - min_i}$$

pri čemu je:

- X_i standardizirana vrijednost kriterija,
- x_i originalna vrijednost kriterija,
- min_i donja granica brojčanog intervala,
- max_i gornja granica brojčanog intervala

Za većinu ulaznih slojeva ili za analize koje nemaju visoku važnost takav pristup standardiziranju kvantitativnih vrijednosti je sasvim dovoljan, međutim prisutan je očit nedostatak linearnog skaliranja, a to je vidljivo ukoliko je prisutno nekoliko elemenata sloja čije vrijednosti znatno odstupaju od ostalih. Jedan od primjera takve pojave je standardizacija rastera akumulacije padalina, obzirom da se padaline postepeno spuštaju do nekoliko najnižih točaka terena u koje se potom slijevaju padaline s izuzetno velikog broja piksela. U tom slučaju nakon linearnog skaliranja unutar raspona 0-100, većina piksela imala bi vrijednost blisku nuli, dok bi tek nekolicina imala vrijednost veću od 20, 50 ili blizu 100 te se time ne bi pravilno interpretirao postavljeni kriterij i čime bi se naštetilo konačnom rezultatu analize. Rješenje za takav slučaj može se postići subjektivnim „rezanjem“, odnosno reklasifikacijom dijela vrijednosti sloja do logične minimalne ili maksimalne vrijednosti i normalnim pristupom linearnom skaliranju.

Prisutne su i metode standardizacije koje omogućuju veći utjecaj korisnika na rezultat standardizacije i time potencijalno dobivanje kvalitetnijeg rezultata standardizacije, a to su klasiranje vrijednosti ulaznog sloja i metode nejasne logike (eng. *fuzzy measures*). Metoda klasiranja vrijednosti ulaznog sloja provodi se na način da korisnik odredi nekoliko (uglavnom do 5) klasa, zatim pridruži granične vrijednosti svakoj klasi i potom dodijeli nove vrijednosti unutar određenog intervala svakoj klasi ovisno o njihovoj pogodnosti za rezultat. Metode nejasne logike temelje se na nelinearnom skaliranju ulaznih vrijednosti unutar određenog brojčanog intervala. Krivulja ovisnosti originalnih i standardiziranih vrijednosti tako umjesto ravne linije kao kod linearnog skaliranja, poprima nepravilan oblik (krivulje oblika slova S, kombinirano krivulje i ravne linije i sl.).

Standardizacijom se također omogućava objedinjavanje kvalitativnih (npr. pokrov zemljišta, pedološki podaci i slično) i kvantitativnih podataka (npr. podaci digitalnog modela reljefa), što je i jedna od najvećih prednosti multikriterijalne analize. Na primjer, prilikom rada s intervalom 1-5, trima vrstama tla od kojih postoje povoljna, neutralna i nepovoljna dodijelile bi se vrijednosti od 5 za povoljna, 3 za neutralna i 1 za nepovoljna tla.

3.1.4. Određivanje težina faktora

Tri su glavne metode za određivanje težina faktora i svaka od njih može naći primjenu ovisno o željenom utjecaju korisnika na rezultat analize i detaljnosti analize. Najjednostavnija metoda je metoda rangiranja (eng. *ranking*), koja se temelji na rangiranju

n faktora na ljestvici od 1 do *n* ovisno o njihovom utjecaju i važnosti na objekt analize. Tako bi težine za 4 faktora bile 1, 2, 3 i 4, s tim da bi najutjecajniji faktor imao težinu 4, a najmanje utjecajan težinu 1. Razlika između dvije susjedne težine dobivene ovom metodom je relativno velika, a samim time je ta metoda pogodna samo za jednostavnije analize.

Metoda procjene (eng. *rating*) također je jednostavna za primjenu, no omogućava određeniju razdiobu težina po faktorima i veći utjecaj korisnika. Vrši se na principu određivanja utjecaja pojedinog faktora pridruživanjem razine utjecaja u postocima (0-100%) i njegovim preračunavanjem unutar brojčanog intervala 0-1. Važno je napomenuti da zbroj tih vrijednosti mora poprimiti 100%, odnosno 1. Pritom se faktori ne rangiraju po važnosti, pa tako dva ili više faktora mogu imati istu težinu, ukoliko korisnik procijeni da imaju približno jednak utjecaj na konačni rezultat. Obzirom da metoda procjene omogućava brzo, a ujedno i kvalitetno definiranje težina, ima trenutno najširu primjenu u multikriterijalnoj analizi od navedenih metoda.

Metoda kreiranja matrice usporedbe parova (eng. *pairwise matrix*) (Saaty,1980) je metoda određivanja težina faktora na temelju međusobnog uspoređivanja relativne važnosti faktora u multikriterijalnoj analizi. Osnovni princip je da se unutar pojedinog para uspoređivanih faktora, važnijem faktoru dodjeli broj u intervalu 1-9, a manje važnom faktoru recipročna vrijednost odabranog broja. Vrijednost faktora 1 označava jednaku važnost, a vrijednosti do 9 proporcionalno sve veću važnost u odnosu na faktor s kojim se vrši usporedba. Usporedba se vrši za svaku moguću kombinaciju dva faktora, tako da je primjerice za 4 faktora potrebno izvršiti 6 različitih usporedbi. Na temelju usporedbi kreira se matrica iz koje se računaju vektori, tj. težine za pojedine faktore. Takav pristup omogućava vrlo temeljito određivanje težina uz velik utjecaj korisnika, međutim postoji očit nedostatak kod nepraktičnosti računanja s većim brojem faktora. Tako bi primjerice za 8 faktora postojalo 28 mogućih kombinacija, što znatno otežava održavanje istog subjektivnog kriterija procjene pri usporedbi za tako velik broj.

3.1.5. Izračun rezultata

Standardizirane vrijednosti faktora i njihove težine te ograničenja u ovom koraku se objedinjuju (eng. *aggregate*) u svrhu dobivanja konačnog rezultata multikriterijalne analize, odnosno pogodnosti za pojedini piksel ukoliko se radi s rasterskim slojevima. Najčešće korištena metoda objedinjavanja je metoda težinske linearne kombinacije (eng. *weighted linear combination*). Temelji se na zbrajanju umnožaka standardiziranih vrijednosti faktora

i njihovih težina te potom množenju dobivenog zbroja s umnoškom ograničenja koji sadrži isključivo vrijednosti 0 ili 1. Općenita formula glasi:

$$\text{pogodnost} = \sum X_i t_i \text{ x } \Pi O_j$$

pri čemu je:

- X_i standardizirana vrijednost faktora,
- t_i težina faktora,
- O_j ograničenje i
- Π umnožak ograničenja

Metoda poredanih težina (eng. *ordered weighted averaging*, OWA) osim standardiziranih vrijednosti faktora i njihovih težina u računanje pogodnosti uvodi još jedan set podataka, a to je redoslijed težina. Za razliku od metode težinske linearne kombinacije, gdje velik utjecaj (umnožak vrijednosti i težine) jednog faktora može kompenzirati nizak utjecaj nekog drugog faktora, metoda poredanih težina kroz rangiranje faktora uzima takve pojave u obzir tijekom računanja rješenja korištenjem operatora *fuzzy* logike.

Nakon određivanja pogodnosti svakog piksela na području od interesa, moguće je izvesti preklapanje s vektorskim slojem koji sadrži katastarske čestice, poljoprivredne čestice ili administrativne jedinice. Tako se svakom poligonu pridružuje aritmetička sredina vrijednosti piksela (pogodnost) koji se preklapaju s poligonom, olakšavajući donošenje odluke ukoliko postoji konačan broj čestica na terenu na kojima je moguće izvršiti predmet analize (sagraditi objekt, posaditi/posijati određenu kulturu i slično). Dodatna mogućnost je prikupljanje svih čestica u vektorskom obliku na kojima je predmet analize otprije prisutan ili uspostavljen te procjena učinkovitosti predmeta analize na tim česticama temeljem izračunate pogodnosti za to područje. Drugim riječima, ako je multikriterijalnom analizom određena pogodnost za uzgoj pšenice, preklopom dobivene pogodnosti s poljoprivrednim česticama na kojima je tijekom prethodne godine uzgajana pšenica moguće je procijeniti učinkovitost poljoprivredne proizvodnje pšenice na tim česticama. Provjera takvog postupka izvediva je prikupljanjem podataka o količini uroda na tim česticama i uspostavljanjem odnosa između kvantitativnih podataka uroda i izračunate pogodnosti.

3.1.6. Analiza rezultata i ocjena točnosti

Posljednjim korakom u multikriterijalnoj analizi korisnik procjenjuje valjanost rješenja koristeći referentne podatke koji se smatraju točnima, a nisu korišteni u multikriterijalnoj analizi. Primjer takvih referentnih podataka mogu biti podaci dobiveni iz nadležnih institucija, prijašnjih istraživanja, podaci terenskog opažanja i slično. Bez obzira na općenit digitalni karakter multikriterijalne analize i GIS-a, terensko opažanje je nezaobilazan korak prilikom obrade prostornih podataka. Njime se dobivaju najsvježiji podaci s terena te omogućuje procjenu korisnosti analize u stvarnosti, odnosno procjenu je li najbolji rezultat analize primjenjiv na terenu i postoje li neki objekti i pojave koji nisu obuhvaćeni multikriterijalnom analizom, a imaju utjecaj na konačni rezultat.

Korisnik također procjenjuje utjecaj pojedinih kriterija, odnosno težina na konačni rezultat multikriterijalne analize i po potrebi provodi iterativan postupak ponavljanjem nekih koraka u analizi, prije svega ubacivanje ili izbacivanje pojedinih kriterija te promjenu vrijednosti i težina faktora. Kako bi procijenio kvalitetu provedene analize, korisnik bi trebao imati odgovarajuću razinu znanja o predmetu analize i provesti subjektivnu kontrolu rezultata.

3.2. GIS programi za multikriterijalnu analizu prostornih podataka

Gotovo svi GIS programi podržavaju izvršavanje potrebnih operacija unutar multikriterijalne analize, obzirom da su za njezino provođenje dovoljne osnovne GIS operacije, kao što su raster kalkulator, operacije nad skupovima (unija, razlika, presjek, itd.) te alati za reklasifikaciju i standardizaciju. Prilikom provođenja multikriterijalne analize najznačajniju ulogu ima korisnik, a kao i u većini analiza i istraživanja, program služi samo kao alat za njihovo izvođenje. Prema tome, GIS programi razlikuju se ovisno o mjeri u kojoj su operacije potrebne za izvođenje multikriterijalne analize automatizirane i prilagođene korisniku.

Općenito se GIS programi mogu podijeliti na dvije kategorije: slobodne i komercijalne, te će u nastavku biti opisani neki od njih.

3.2.1. Slobodni GIS programi

Slobodni GIS programi, koji su uglavnom otvorenog koda (eng. *open source software*), besplatni su za korištenje te se njihova struktura i rad može prilagoditi ovisno o potrebama korisnika (ukoliko su otvorenog koda). Obično ih razvijaju neprofitne organizacije, sveučilišta ili nezavisni stručnjaci. Zbog jednostavnosti i dostupnosti izuzetno su pogodni za obrazovanje, međutim mnogi od njih su i izuzetno kvalitetni te omogućuju izvršavanje vrlo zahtjevnih i kompleksnih GIS analiza i operacija. Najpoznatiji GIS programi otvorenog koda po učinkovitosti su tako uz bok najboljim komercijalnim programima, a neki od njih su QGIS, SAGA GIS i GRASS GIS.

QGIS (prethodno Quantum GIS) je vodeći GIS program otvorenog koda u svijetu razvijen u okviru službenog projekta *Open Source Geospatial Foundation* (OSGeo) zajednice (QGIS (2017)). Korisničko sučelje QGIS-a je vrlo prilagođeno potrebama korisnika (eng. *user friendly*) i pruža mogućnost korištenja alata iz ostalih GIS programa otvorenog koda (npr. SAGA GIS, GRASS GIS), pa služi kao univerzalno sredstvo za izradu GIS analiza i kartografskih prikaza. Komponenta koja odvaja QGIS od ostalih programa su dodaci (eng. *plugins*), koji proširuju mogućnosti programa i omogućuju izvršavanje dodatni operacija.

SAGA GIS (*System for Automated Geoscientific Analyses*) (Conrad i dr, 2015.) je GIS program otvorenog koda razvijen na sveučilištima u Göttingenu i Hamburgu. Omogućava izvršavanje velikog broja temeljnih i naprednih GIS operacija s naglaskom na geoznanstvenu analizu. Sadrži okruženje vrlo pogodno za napredne matematičke operacije nad podacima, pa tako sadrži i brojne ugrađene operacije za multikriterijalnu analizu, kao što je određivanje težina matricom usporedbe parova, standardizacija podataka *fuzzy* metodama i metoda poredanih težina.

GRASS GIS je, kao i QGIS, GIS program otvorenog koda razvijen u okviru službenog projekta OSGeo zajednice, a prvotno je razvijan od strane inženjerskog odsjeka vojske SAD-a. Glavna karakteristika GRASS-a je *location/mapset* način rada, odnosno rad unutar određenog okvira s definiranim referentnim koordinatnim sustavom i graničnim koordinatama, pri čemu je omogućen istovremen rad više osoba ili cijelog tima unutar istog GIS projekta (GRASS GIS (2017)). GRASS sadrži određene kompleksne operacije za

multikriteralnu analizu, kao i za GIS općenito, čime se odlično nadopunjava s prethodno opisanim programima otvorenog koda.

3.2.2. Komercijalni GIS programi

Komercijalni GIS programi razvijani su od strane većih korporacija i dostupni su korisnicima uz plaćenu licencu, izuzevši nekoliko dopunskih ili ograničenih potprograma. Odlikuju ih vrlo dobra korisnička podrška i detaljna dokumentacija, za razliku od nekih GIS programa otvorenog koda. Vodeći komercijalni GIS programi omogućavaju izvršavanje gotovo svih poznatih GIS operacija i analiza, a osim toga često dolaze u oblicima koji su u potpunosti namijenjeni i prilagođeni specifičnim strukama.

ArcGIS program tvrtke ESRI trenutno je vodeći GIS komercijalni program. Omogućuje izuzetno kvalitetnu obradu podataka i najkompleksnije operacije u svim segmentima GIS-a i obrade prostornih podataka te ima odličnu korisničku podršku i razgranatu bazu korisnika. To se odnosi i na multikriterijalnu analizu, gdje su osim brojnih operacija i opisa metodologije rada dostupne povratne informacije korisnika. Kao i QGIS, sadrži dodatke koji dodatno proširuju njegove funkcionalnosti.

IDRISI program tvrtke CLARK LABS je, kao i ArcGIS, komercijalni GIS program s dugom tradicijom i alatima za najkompleksnije GIS operacije i analize. Orijentiran je primarno na rasterski GIS. Što se multikriterijalne analize tiče, sadrži module za *fuzzy* operacije, čak i automatiziran cijeli postupak analize.

4. REZULTATI I RASPRAVA

Kao tema ovog diplomskog rada odabrano je izvršavanje multikriterijalne analize u poljoprivredi te je odabrano traženje pogodnosti područja za uzgoj lijeske na području Vukovarsko-srijemske županije. Obzirom da se radi o velikoj investiciji pri uspostavljanju nasada lijeske i velikom značaju lješnjaka u prehrani čovjeka, multikriterijalna analiza pruža važan alat pri odlučivanju o položaju sadnje i ostalim elementima uzgoja. Područje analize je Vukovarsko-srijemska županija kako bi se izradio primjer analize u Slavoniji za poljoprivredu, obzirom da nešto slično nije pronađeno prilikom pretraživanja članaka i materijala.

Prije pristupanja koracima u izvršavanju multikriterijalne analize uvijek je korisno izvršiti detaljno istraživanje predmeta analize i područja analize u svrhu dobivanja što kvalitetnijeg rezultata. Tako su u nastavku opisane karakteristike lijeske i posebnosti Vukovarsko-srijemske županije, a koje su od interesa za ovu multikriterijalnu analizu.

4.1. Lijeska

Za prikupljanje podataka o lijeski korišteni su web izvori Plantea (2017) i Agroklub (2017). Posebna pažnja je posvećena karakteristikama lijeske i utjecajima na njezin uzgoj koji su povezani s prostorom, odnosno koji se mogu modelirati pomoću nekog oblika prostornih podataka.

4.1.1. Karakteristike lijeske

Obična lijeska (lat. *Corylus avellana*) (slika 18.) je listopadni grm ili niže stablo iz porodice brezovki. Raste najčešće kao grm do 4 metara visine no kao niže stablo naraste i do 15 m. Deblo je promjera do 20 cm, kora je glatka, tanka, crvenkastosiva do smeđa, kasnije plitko ispuca. Korijen je plitak no široko i dobro razgranat, nema središnju žilu. Mladi izboji su koljenčasto ispresavijeni u cik-cak liniji, žutosmeđi do sivosmeđi, u početku prekriveni dlačicama i prekriveni karakterističnim bijelim točkicama – lenticelama, kasnije ogole. Pupovi su naizmjenični, zeleni ili sivi, krupni, jajasti, tupi, veliki do 3 mm, ljuske su na rubu trepavičaste. Listovi su obrnuto jajasti, dugi 5-13 cm, široki 5-9 cm, pri osnovi srcoliki, na rubovima nepravilno nazubljeni i nalaze se na kratkim, oko 0,5-2 cm dugim, žljezdasto dlakavim peteljkama. Lice im je tamnije zeleno i skoro golo, naličje im je

svijetlozeleno i dlakavo, nervatura je perast i uzduž žila su dlačice. Pri osnovi im se nalaze dva mala palistića koji brzo otpadnu.



Slika 18. Stablo lijeske
Izvor: Moulis (2017)

Lijeska je jednodomna biljka što znači da se muški i ženski cvjetovi nalaze na istoj biljci. Cvate prije listanja, vrlo rano, već i u siječnju ako su povoljni uvjeti, no obično u veljači i ožujku. Na jednom grmu cvatnja traje oko tjedan dana. Muški cvjetovi (slika 19.) su u obliku resa koje se formiraju već tokom jeseni i u rano proljeće se otvaraju. Grupirane su po dvije do četiri rese, svaka dužine 5-7 cm no u fazi punog cvjetanja dugačke su i do 20 cm. Cvjetovi su bez ocvijeća, a imaju 4 prašnika koji su razdijeljeni u gornjem dijelu te na koncu broje 8 prašnica koje na vrhu nose čuperak dlaka. Ženski cvjetovi su jedva vidljivi, veliki oko 0,5 cm, razvijaju se na jednogodišnjim izbojima u tamnocrvenom cvatu u obliku zbijenih pupova. Tučak je jedan, ocvijeće im je sraslo s plodnicom. Nakon uspješnog oprašivanja vjetrom razvijaju se široko jajasti plodovi (slika 20.). Do 4 takva ploda smještena su zajedno i u svakom plodu obavijenom čvrstom drvenastom ljuskom nalazi se jedna sjemenka. Plod je dug 1,5-2,5 cm, okružen jednostrukim ovojem nalik na listove koji su nazubljenih ili režnjevitih rubova, u početku zeleni, kasnije postanu smeđi, vršci im dopiru do vrha lješnjaka. Dozrijevaju u kolovozu i rujnu. Cvjetovi pčelama daju velike količine peludi, nektara nema.



Slika 19. Muški cvjetovi lijeske (rese)

Izvor: Moulis (2017)



Slika 20. Plod lijeske

Izvor: Moulis (2017)

4.1.2. Uzgoj lijeske

Razmnožavanje lijeske moguće na više načina, no najčešće se primjenjuje razmnožavanje reznicama i izdancima je jer je vrlo jednostavno i jeftino. Tijekom jeseni uzimaju se reznice duge 20 cm i preko zime drže u vlažnom pijesku na temperaturi oko 10 °C i u rano proljeće sade se u vlažan supstrat na zaštićeno mjesto dok ne ojačaju. Razmnožavanje položenicama radi se na jednogodišnjim mladicama koje se polažu uz tlo i prekriju zemljom. Lijeska ima i dobru izbojnu snagu iz panja.

Berba lješnjaka obavlja se od kraja srpnja do početka listopada, ovisno od osobina sorte i područja uzgoja. Plodovi su zreli kada promjene boju i kada lako ispadaju iz omotača.

Sasvim zreli plodovi su žutosmeđe boje. Prerano obrani plodovi gube na kvaliteti, a jezgre su smežurane i žilave. U nekim slučajevima berba može biti otežana jer ne dozrijevaju svi plodovi istovremeno te se kod nekih sorata plodovi teško oslobađaju iz omotača. Prilikom berbe plodovi imaju oko 30 - 35% vode, pa se suše na temperaturi do 40 °C dok se postotak vode ne spusti do uobičajenih 10%.

4.1.3. Stanište lijeske

Prirodno raste u umjerenom pojasu Europe i jugozapadne Azije. Nalazimo je samoniklu od nizina do 1800 m nadmorske visine, raste u šikarama, na rubovima šuma, na vlažnim, dubokim humusnim tlima. Rasprostranjena je u zonama hrasta kitnjaka, hrasta lužnjaka, jasena i bukve. Životni vijek joj je do 100 godina. Vrlo često se uzgaja se kao prehrambena biljka.

Lijeska nije pretjerano izbirljiva prema tlu, može uspijevati i na siromašnijem tlu, no za obilne prinose najbolja su plodna, duboka i vapnenasta tla zbog formiranja plodova. U kontinentalnoj Hrvatskoj dobri položaji za lijesku su oni s nadmorskom visinom iznad 140 m i s odgovarajućim reljefom. Uspješno se uzgaja na položajima za uzgoj vinove loze. Također joj je potreban sunčan položaj i vlažno tlo jer u uvjetima zasjene ili suše tijekom ljeta slabo rađa. Zadovoljavajuće su količine oborina u čitavoj godini 800 - 1200 mm, od toga u vegetaciji (travanj i rujan) barem 350 - 400 mm, odnosno za razdoblje travanj - srpanj ukupno 280 mm. Osjetljiva je na niske temperature. Niske temperature zraka izazivaju smrzavanje jednogodišnjih izboja na -30 °C, vegetativnih pupova na -25 °C, neotvorenih muških i ženskih cvatova na -18 do -16 °C, otvorenih muških i ženskih cvatova na -7 do -10 °C i pupova lišća u početku vegetacije na -3 do -5 °C. Zbog oprašivanja vjetrom pogodni su otvoreni prostori.

4.2. Vukovarsko-srijemska županija

Vukovarsko-srijemska županija smještena je na krajnjem sjeveroistoku Republike Hrvatske. Leži u međuriječju Dunava i Save, i zauzima dijelove povijesnih pokrajina istočne Slavonije i zapadnog Srijema. Na tom području male su visinske razlike. Najviša je točka Čukala kod Iloka (294 m nadmorske visine), a najniža u Posavini - Spačva (78 m). Na istoku se blago spuštaju obronci Fruške gore i prelaze u vukovarski ravnjak. Sa zapada, s planine Dilj, pruža se vinkovačko-đakovački ravnjak.

Ovim područjem vode važni riječni i kopneni putovi i križaju se međunarodni prometni pravci od istoka prema zapadu uz rijeku Dunav, te od sjevera preko rijeke Save prema Jadranskom moru. Tu se dotiču i sučeljavaju civilizacije zapadnoeuropskog i istočnog kulturnog kruga. Sjeverno od Vinkovaca teče rijeka Vuka koja se ulijeva u Dunav kod Vukovara, a južnije prema Savi teče Bosut s pritokama Berava, Bid, Studva i Spačva. Bogate ribom te su rijeke utjecale na kontinuitet življenja čemu je pridonijela i plodno praporno tlo. Na gustoću naseljavanja utjecale su i mnogobrojne hrastove šume nikle u nekad močvarama bogatom području južnog dijela Županije. (Turistička zajednica Vukovarsko-srijemske županije (2017))

4.2.1. Poljoprivreda i tlo

Prevladavaju oranice, vinogradi, voćnjaci i šume. Vukovarsko-srijemska županija ima najplodnije oranice (150000 ha vrlo plodnog tla). Najplodnije je tlo crnica na vukovarskom ravnjaku. Tlo, blaga kontinentalna klima i povoljan godišnji raspored oborina ovog podneblja omogućavaju kvalitetnu poljoprivrednu proizvodnju. Ratarske površine su meliorirane i komasirane i omogućuju strojnu obradu i visoke prinose. Glavni proizvodi su: pšenica, kukuruz, šećerna repa te duhan. Postoje veliki prerađivački kapaciteti za primarne poljoprivredne proizvode, skladišta, mlinovi, silosi, hladnjače i tvornice. Veliko bogatstvo čine sačuvane stare šume koje pokrivaju površinu od 70000 ha. Naročito su poznate šume hrasta lužnjaka. U spačvanskom šumskom bazenu dva su zaštićena šumska područja: Lože, kod Županje, i Radiševo, zaštićeno šumsko područje blizu naselja Vrbanja. (Vukovarsko-srijemska županija (2017))

4.2.2. Klima

Prostor Vukovarsko-srijemske županije ima umjereno kontinentalnu klimu. Ljeta su sunčana i vruća, a zime su hladne i sa snijegom. Srednja godišnja temperatura kreće se oko 11 °C sa srednjim najtoplijim maksimumom od 29,9 °C i srednjim minimumom od 12,2 °C. Srednje godišnje padaline kreću se u relativno uskom rasponu. Najniže su u krajnjem istočnom dijelu gdje iznose oko 650 mm, a idući prema zapadu vrijednost srednjih godišnjih padalina postupno raste do 800 mm. Najviše padalina ima u proljeće i sredinom ljeta, što pogoduje usjevima. Srednja relativna vlaga iznosi 79%. (Vukovarsko-srijemska županija (2017))

4.3. Multikriterijalna analiza pogodnosti uzgoja lijeske na području Vukovarsko-srijemske županije

Proces analize oslanja se na prethodno definirane teoretske korake. Pritom je obuhvaćeno više različitih vrsta kriterija i rješavanje nekoliko čestih problema tijekom multikriterijalne analize te su korištene najčešće upotrebljavane metode za svaki od izvršenih koraka. Program korišten za obradu podataka je SAGA GIS. Kao što je spomenuto, lijeski odgovaraju veće nadmorske visine, zahtjeva dovoljnu količinu vlage u tlu tijekom cijele godine i ne podnosi niske temperature. Općenito podnosi i nešto lošija tla, iako urod poprilično ovisi i o kvaliteti tla. Obzirom na dostupne izvore prostornih podataka, s ciljem što boljeg modeliranja navedenih uvjeta korišteni su sljedeći kriteriji (tablica 1.):

Tablica 1. Prostorni kriteriji multikriterijalne analize pogodnosti uzgoja lijeske

Naziv	Opis	Izvor podataka	Vrsta kriterija
Nadmorska visina	Digitalni model visina u rasterskom obliku	SRTM 1 lučne sekunde, globalni digitalni model visina	faktor
Vrsta tla	Pedološki podaci u vektorskom obliku	Izvedeno iz osnovne pedološke karte 1:50000 i ostalih podataka (Vidaček i sur. (2010))	faktor
Insolacija	Predviđena ukupna insolacija tijekom 2017. godine	Izvedeno iz digitalnog modela visina	faktor
Udaljenost prometnica	Udaljenost piksela do najbliže prometnice	Izvedeno iz podataka *Open Street Map*-a	faktor
Izloženost vjetru	Izloženost područja naletima vjetra obzirom na strukturu reljefa	Izvedeno iz digitalnog modela visina	faktor
Najniža temp. siječanj	Prosječna najniža temperatura u siječnju (2013.-2017.)	Interpolirana površina iz podataka s *World Weather Online*-a (2017.)	faktor
Prosječna temp. veljača	Prosječna srednja temperatura u veljači (2013.-2017.)	Interpolirana površina iz podataka s *World Weather Online*-a (2017.)	faktor
Godišnja količina kiše	Prosječna godišnja količina kiše (2015.-2016.)	Interpolirana površina iz podataka s *World Weather Online*-a (2017.)	faktor
Zaštićena područja	Područja zaštićena od strane RH	NATURA 2000	ograničenje

Kriteriji reljefa obuhvaćaju nadmorske visine, predviđenu ukupnu količinu insolacije za 2017. godinu i indeks izloženosti vjetru. Nadmorska visina jedan je od najvažnijih kriterija u analizi i povoljniji je što je visina terena veća. Insolacija je korištena zbog činjenice da lijeski odgovaraju više temperature i svjetlost (kao i većini biljaka), a veća izloženost vjetru također je označena kao pogodnija.

Meteorološkim kriterijima pripadaju najniža temperatura u siječnju (jer lijeski ne odgovaraju jako niske temperature u vrijeme pupanja) i prosječna temperatura u veljači (vrijeme cvatnje) te količina kiše tijekom godine.

Pedološki kriterij iskazan je oznakom pogodnosti tla u Pedološkoj karti RH (Vidaček i sur. (2010)). Kvalitativni podaci iz pedološke karte reklasificirani na način da poprimaju vrijednosti unutar zadanog brojčanog intervala. Tla su općenito podijeljena na četiri kategorije, kojima su pridružene vrijednosti na način prikazan u tablici 2.

Tablica 2. Kategorije pogodnosti u korištenoj pedološkoj karti

Izvorna oznaka pogodnosti tla (Vidaček i sur. (2010))	Opis oznake pogodnosti	Nova vrijednost
0	Područje na kojem tlo nije prisutno (vode)	0 (0)
N-1	Nepogodna tla	10 (2)
P-3	Ograničeno obradiva tla	50 (3)
P-2	Ograničeno obradiva tla	70 (4)
P-1	Dobra, obradiva tla	100 (5)

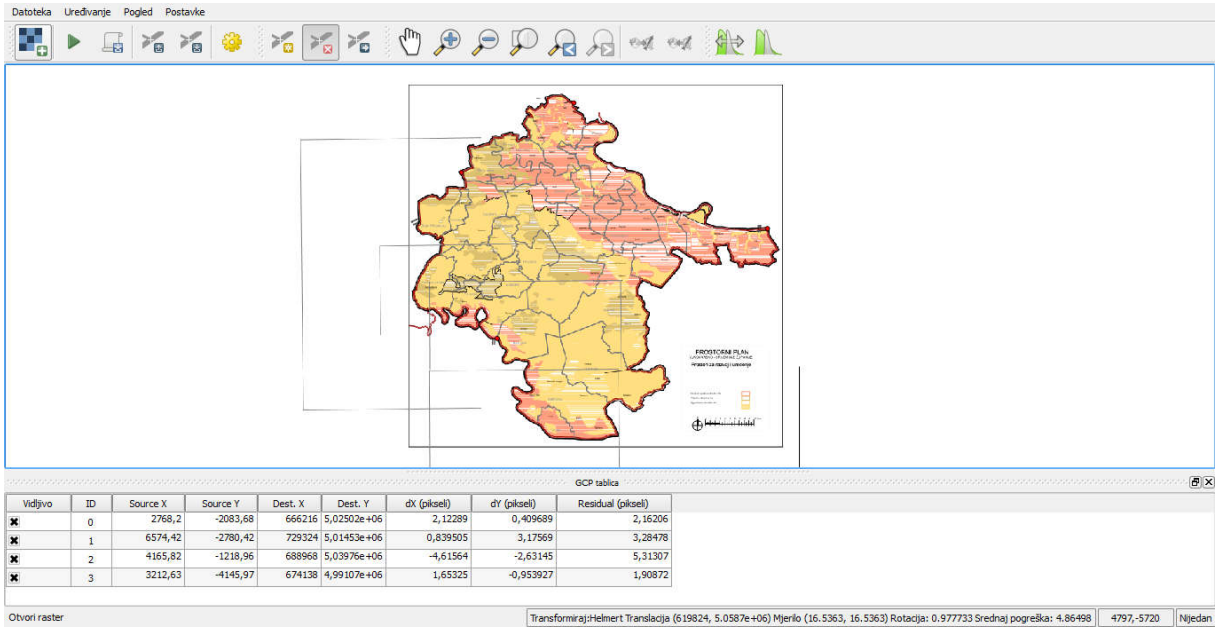
Kriterij infrastrukture predstavlja udaljenost nekog područja od najbliže prometnice većeg reda. Veća udaljenost od prometnica je označena kao pogodna, jer samim time je manje i zagađenje zraka.

4.3.1. Priprema podataka za multikriterijalnu analizu

Priprema podataka za multikriterijalnu analizu u GIS okruženju, odnosno prostornih podataka koje predstavljaju postavljene kriterije, izvršena je standardnim GIS metodama obrade vektorskih i rasterskih prostornih podataka. Detaljnije će biti objašnjeni oni

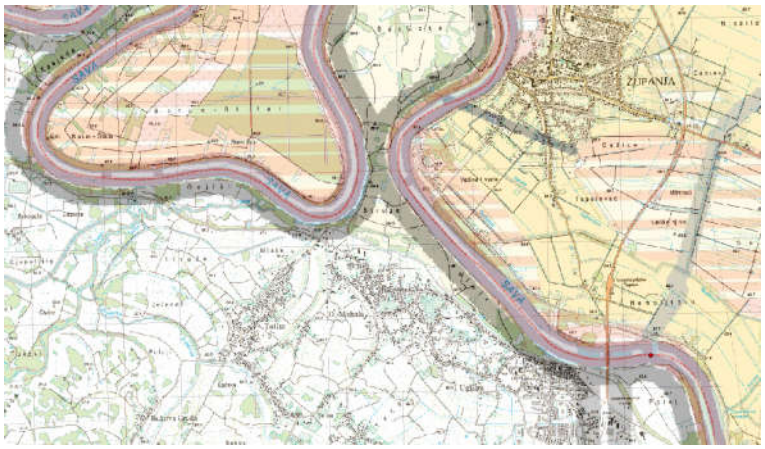
kompleksniji, postupak vektorizacije granica jedinica lokalne samouprave (općina) i interpolacija meteoroloških podataka.

Vektorizacija granica općina Vukovarsko-srijemske županije provedena je iz podataka prostornog plana, preuzetog sa stranica županije u dwf formatu. Dobivena datoteka konvertirana je u sliku (jpg format) te je georeferencirana u QGIS programu korištenjem 4 točke identificirane na slici u i Arkodu (odakle su očitane njihove koordinate u HTRS96/TM) (slika 21.).



Slika 21. Georeferenciranje prostornog plana Vukovarsko-srijemske županije

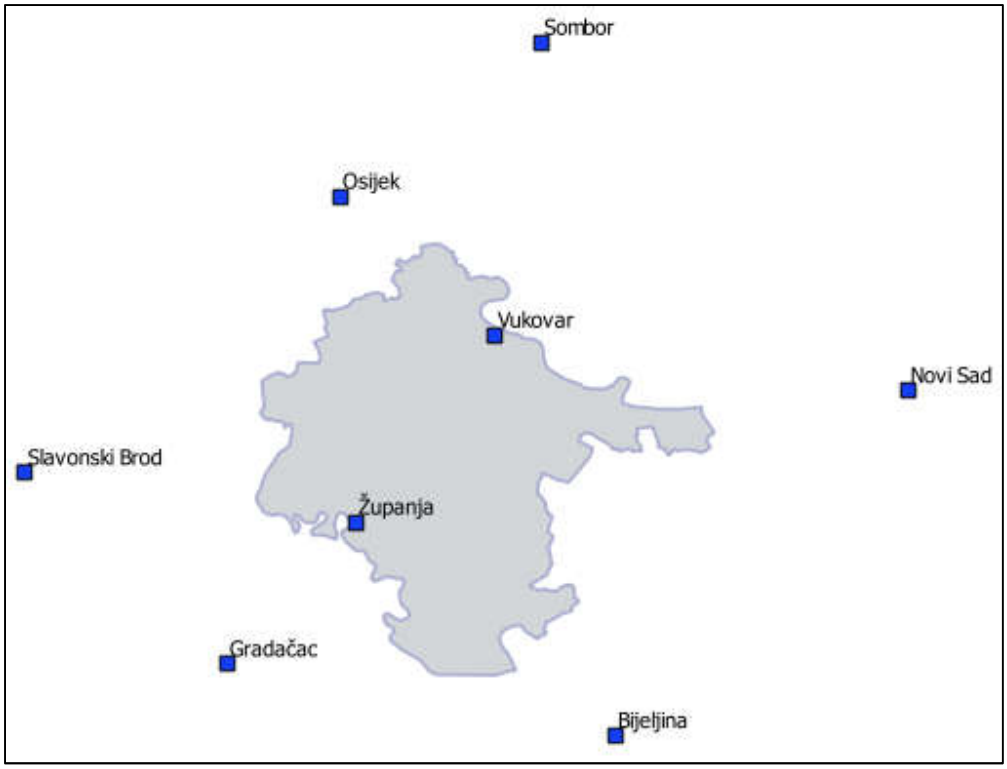
Vektorizacija je obavljena iscrtavanjem linija, obzirom da je takav postupak znatno ekonomičniji od vektorizacije poligonima zbog mnogo objekata iste važnosti (općine). Vektorizirane su zasebno polilinije između dvaju čvorišta (sjecišta dvije ili više linija) kako bi postupak oko prevođenja zatvorene mreže linija u poligone bio što lakši (topologija). Nakon završene vektorizacije, kvaliteta iscrtanih općina provjerena je preklopom s TK25 WMS slojem DGU (slika 22.), iz čega se vidi da linije prolaze točno sredinom rijeke Save, koja predstavlja dio granice županije.



Slika 22. Kontrola kvalitete vektorizacije i georeferenciranja u odnosu na TK25 DGU

Meteorološki podaci za područje Vukovarsko-srijemske županije korišteni u analizi su izrađeni interpolacijom iz točkastih podataka sa 8 meteoroloških stanica (slika 23. i 24.). Podaci su očitani iz prijašnjih nekoliko godina te je određena aritmetička sredina očitanja. Temeljem točkastog vektorskog sloja obavljena je interpolacija u SAGA GIS programu metodom *Inverse Distance Weighted* posebno za svaku vrstu meteoroloških podataka.

Za područje te veličine prikladnije je obaviti interpolaciju s podacima više stanica, no povijesni slobodni meteorološki podaci su na internetu teško dostupni. Za detaljniju analizu bilo bi potrebno koristiti podatke DHMZ promatranih kroz duže vremensko razdoblje.



Slika 23. Meteorološke stanice korištene za interpolaciju (približno mjerilo 1:1 100 000)

	Grad	Temp_velj	Kisa_god	MinT_sij
1	Osijek	6.2	824.94	-0.6
2	Slavonski Brod	6	856.97	-1.4
3	Vukovar	6.4	787.26	-0.2
4	Sombor	6	675.16	-0.4
5	Gradačac	6.6	956.63	-0.8
6	Županja	7	960.28	-1
7	Bijeljina	7.2	753.38	-1
8	Novi Sad	6.4	893.75	-0.6

Slika 24. Podaci korištenih meteoroloških stanica

4.3.2. Primjer multikriterijalne analize (visoka brzina, niska pouzdanost)

Najjednostavniji primjer multikriterijalne analize je korištenje binarne (booleanske) klasifikacije vrijednosti kriterija, odnosno dodjeljivanjem vrijednosti 0 za nepogodno i 1 za pogodno područje. Takav pristup vrlo je pogodan za korisnike koji nemaju mnogo iskustva u radu s GIS-om, a kada pouzdanost rezultata nije prioritet već treba dobiti neku približnu predodžbu o stanju na terenu.

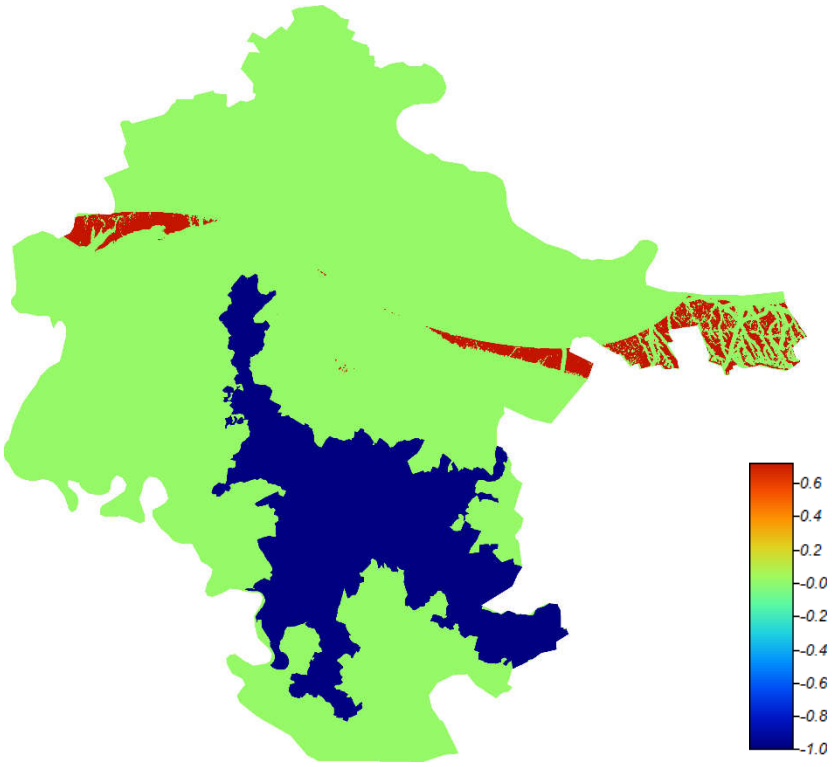
Standardizacija vrijednosti kriterija obavlja se, kao što je spomenuto, dodjeljivanjem vrijednosti 0 ili 1, čime se svi ulazni slojevi kriterija ponašaju kao ograničenja, a ne kao faktori što je bila njihova primarna svrha. Za svaki kriterij tako je određena granična vrijednost i smjer na brojčanom pravcu (tablica 3.). Prikazi izvornih i standardiziranih vrijednosti rastera za svaki korišteni kriterij dani su u prilogu B.

Težine svih slojeva prema tome iznose 1, a kriteriji se objedinjavaju množenjem svih slojeva. Konačan rezultat su tako pikseli koji imaju vrijednost 1 u svim ulaznim slojevima.

U primjeru je sloj ograničenja (Spačvanski bazen) korišten posebno u odnosu na kriterije koji su izvorno definirani kao faktori radi boljeg vizualnog pregleda (slika 25.). Prema rezultatima prvog primjera, područje pogodno za uzgoj lijeske u Vukovarsko-srijemskoj županiji nalazi se na istoku u Općini Ilok te manjim dijelom na zapadu županije.

Tablica 3. Standardizacija vrijednosti kriterija u prvom primjeru

Naziv	Granična vrijednost	Mjerna jedinica
Nadmorska visina	100 +	Metar
Vrste tla	P-3 i bolje	Kvalitativno
Insolacija	1650 +	kWh/m^2
Udaljenost prometnica	200 +	Metar
Izloženost vjetru	1 +	Bezdimenzionalno
Najniža temp. siječanj	-0,75 +	Stupanj Celzija
Prosječna temp. veljača	6,5 +	Stupanj Celzija
Godišnja količina kiše	825 +	Milimetar



Slika 25. Rezultat prvog primjera multikriterijalne analize (crveno – pogodno, zeleno – nepogodno, plavo – ograničeno)

4.3.3. Primjer multikriterijalne analize (srednja brzina, srednja pouzdanost)

Multikriterijalna analiza umjerene brzine i pouzdanosti obuhvaća najekonomičnije metode u svim koracima analize, čime se zadovoljava većina potreba korisnika uz zadovoljavajuću brzinu izrade rezultata. (Uz uvjet da ulazni slojevi ne sadrže ili su korigirani za utjecaj ekstremnih vrijednosti koje nemaju značaja za kvalitetu analize. Ovdje korekcija nije urađena baš kako bi u rezultatima bio izražen taj utjecaj.)

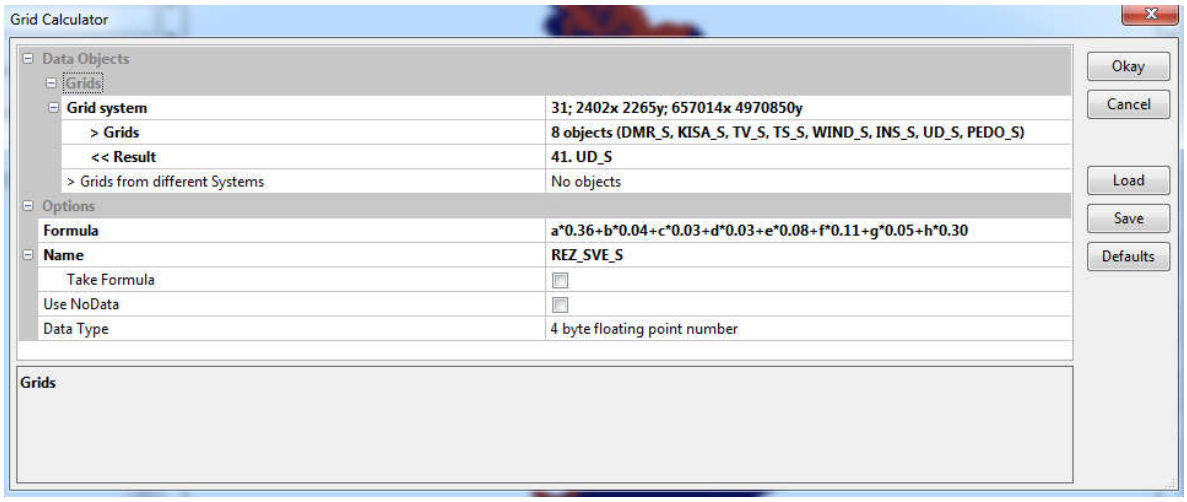
Kao metoda standardizacije vrijednosti faktora korišteno je linearno skaliranje unutar brojčanog intervala 1-100, pri čemu 1 označava najmanju, a 100 najveću pogodnost faktora. Vektorski slojevi prethodno su prebačeni u rasterski oblik kako bi se olakšao daljnji postupak računanja. Prikazi izvornih i standardiziranih vrijednosti rastera za svaki korišteni faktor dani su u prilogu D.

Težine faktora određene su metodom procjene na temelju subjektivne procjene obzirom na dostupne kriterije. Njihov procijenjeni utjecaj na pogodnost područja za uzgoj lijeske i odgovarajuće težine dani su u tablici 4. Radi veće pouzdanosti dodjeljivanja težina, obzirom da postupak u potpunosti ovisi o korisniku, prvo su dodijeljene težine za grupe kriterija (reljef, meteorologija, pedologija i infrastruktura) te je potom iskazan utjecaj pojedinog kriterija unutar grupe. Konačne težine pojedinih faktora dobivene su množenjem težine grupe s udjelom težine u odgovarajućoj grupi.

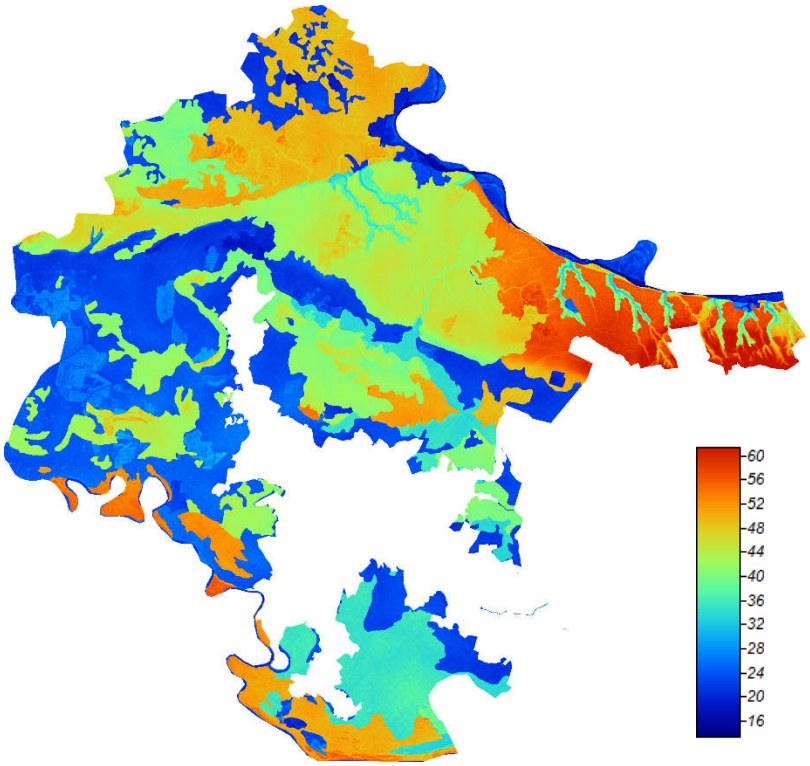
Konačne vrijednosti pogodnosti područja za uzgoj lijeske dobivene su objedinjavanjem standardiziranih vrijednosti faktora i njihovih težina metodom težinske linearne kombinacije te množenjem tih vrijednosti s rasterom ograničenja (slika 26.). Prikaz konačne pogodnosti dan je na slici 27., čije vrijednosti se uglavnom nalaze unutar intervala od 20 do 60 (maksimalno moguće 100).

Tablica 4. Težine faktora u drugom primjeru multikriterijalne analize

Faktor	Težina grupe	*Udjel težine u grupi*	Pojedinačna težina
Nadmorska visina	55%	*65%*	0,36
Insolacija		*20%*	0,11
Izloženost vjetru		*15%*	0,08
Najniža temperatura siječanj	10%	*30%*	0,03
Srednja temperatura veljača		*30%*	0,03
Godišnja količina kiše		*40%*	0,04
Vrsta tla	30%		0,30
Udaljenost od prometnica	5%		0,05
UKUPNO	100%		1,00



Slika 26. Računanje rezultata metodom težinske linearne kombinacije u SAGA GIS programu



Slika 27. Konačni rezultat drugog primjera multikriterijalne analize

Najviše vrijednosti pogodnosti u ovom primjeru su na području Općine Ilok, slično kao i u prethodnom primjeru. Područja na sjeveru i samom jugu županije uz rijeku Savu također sadrže visoku pogodnost za uzgoj lijeske. Sukladno dodijeljenim težinama, najpogodnija su područja koja imaju visoku pogodnost nadmorske visine i vrste tla, dok ostali kriteriji (prije svega insolacija i izloženost vjetru) omogućavaju preciznije razlikovanje pogodnosti nekog područja od njegove okoline.

4.3.4. Primjer multikriterijalne analize (niska brzina, visoka pouzdanost)

Za visoku kvalitetu multikriterijalne analize, pri čemu vrijeme ne predstavlja ograničenje u izvršavanju zadatka, korištena je metoda klasiranja pri standardizaciji vrijednosti kriterija (unutar intervala 1-5) te metoda matrice usporedbe parova za određivanje težina faktora.

Metodom klasiranja korisnik ima znatno veći utjecaj pri standardizaciji vrijednosti faktora, što osobito dolazi do izražaja ukoliko vrijednosti ulaznog rastera faktora sadrže nekoliko piksela s ekstremnim vrijednostima koje nemaju pozitivan utjecaj na kvalitetu analize. Takve ekstremne vrijednosti u ovom slučaju su „eliminirane“, za razliku od metode linearnog skaliranja gdje se vrijednosti standardiziraju od najniže do najviše vrijednosti. Još

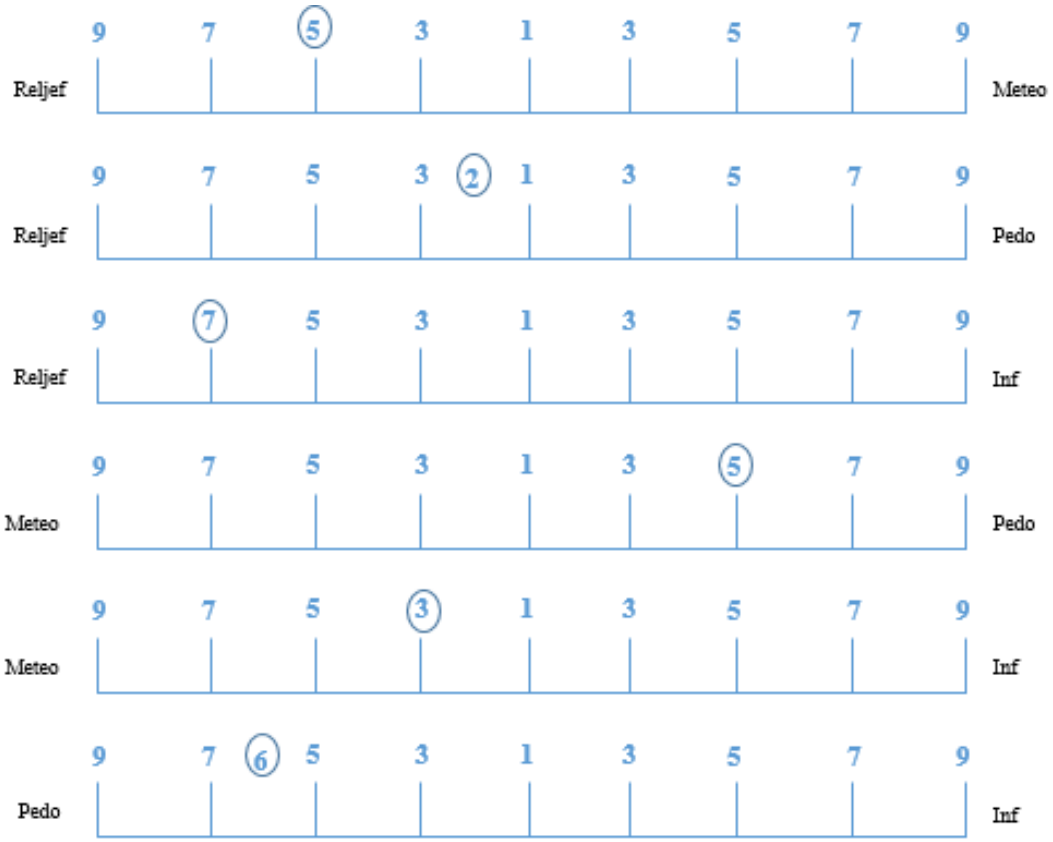
jedna prednost ovakvog pristupa je ukoliko neki faktor ima relativno nisku pogodnost na cijelom području od interesa. Tako bi vrijednosti tog faktora mogle poprimati vrijednosti npr. od 1 do 3 (za interval 1-5), umjesto da se nekim pikselima daje najveća moguća standardizirana vrijednost, a oni u stvarnosti nemaju visoku pogodnost.

Način standardizacije faktora, odnosno granične vrijednosti faktora po razredima, iskazane su u tablici 5.

Tablica 5. Kriteriji u trećem primjeru multikriterijalne analize

Faktor	Standardizirana vrijednost				
	1	**2**	**3**	**4**	**5**
Nadmorska visina [m]	<60	60-80	80-100	100-150	150>
Vrste tla [oznaka pogodnosti]	0	N1	P3	P2	P1
Insolacija [kWh/m^2 godišnje]	<1675	1675-1700	1700-1725	1725-1750	1750>
Izloženost vjetru [/]	<0,8	0,8-0,9	0,9-1,0	1,0-1,05	1,05>
Najniža temperatura siječanj [°C]	<-0,85	-0,85- -0,6	-0,6- -0,45	-0,45- -0,3	-0,3>
Srednja temperatura veljača [°C]	<6,45	6,45-6,6	6,6-6,75	6,75-6,9	6,9>
Godišnja količina kiše [mm]	<800	800-850	850-900	900-950	950>
Udaljenost od najbliže prometnice [m]	<100	100-500	500-1000	1000-1500	1500>

Kao što je spomenuto, težine su određene metodom matrice usporedbe parova, što bi rezultiralo vrlo velikom matricom zbog činjenice da postoji 8 ulaznih faktora u analizi. Umjesto toga, faktori su odvojeni u već spomenute 4 grupe, čiji je utjecaj međusobno procijenjen na način iskazan na slici 28.



Slika 28. Usporedba parova grupa faktora

Slično kao i u prethodnom primjeru, najveći značaj dan je kriterijima reljefa i pedologije, no zbog usporedbe svake grupe kriterija sa svim ostalim grupama, eliminira se nepouzdanost u procjeni vrijednosti težina jer se ovako dobivaju vrijednosti koje održavaju postavljene odnose važnosti između grupa faktora.

Sljedeći korak je formiranje matrice usporedbe grupa faktora, odakle su prenesene vrijednosti usporedbe na način da je važnijoj grupi faktora pridružen određeni cijeli broj, a manje važnoj grupi faktora recipročna vrijednost tog broja za svaku usporedbu (tablica 6.). Vrijednosti stupaca su zbrojene radi obavljanja normalizacije u sljedećem koraku (tablica 7.). Normalizacija se izvodi na način da se pojedini elementi svakog stupca dijele sa zbrojem svih vrijednosti u stupcu. Konačne težine grupe faktora računaju se pomoću aritmetičke sredine vrijednosti elemenata po redovima.

Tablica 6. Matrica usporedbe parova grupa faktora

	Reljef	**Meteorologija**	**Pedologija**	**Infrastruktura**
Reljef	1	5	2	7
Meteorologija	1/5	1	1/5	3
Pedologija	1/2	5	1	6
Infrastruktura	1/7	1/3	1/6	1
Σ	**1,8428**	**11,3333**	**3,3667**	**17,0000**

Tablica 7. Normalizirana matrica usporedbe parova grupa faktora

	Reljef	**Meteorologija**	**Pedologija**	**Infrastruktura**	**Težina**
Reljef	0,5426	0,4412	0,5941	0,4118	**0,4974**
Meteorologija	0,1085	0,0882	0,0594	0,1765	**0,1082**
Pedologija	0,2713	0,4412	0,2970	0,3529	**0,3406**
Infrastruktura	0,0775	0,0294	0,0495	0,0588	**0,0538**

Računanje težina faktora u pojedinim grupama faktora obavljeno je procjenom udjela težine u grupi, na isti način kao i u prethodnom primjeru (tablica 8.). Za svaku grupu može se primijeniti metoda matrice usporedbe parova, no zbog ekonomičnosti postupka ponavljanje takvog procesa je izbjegnuto.

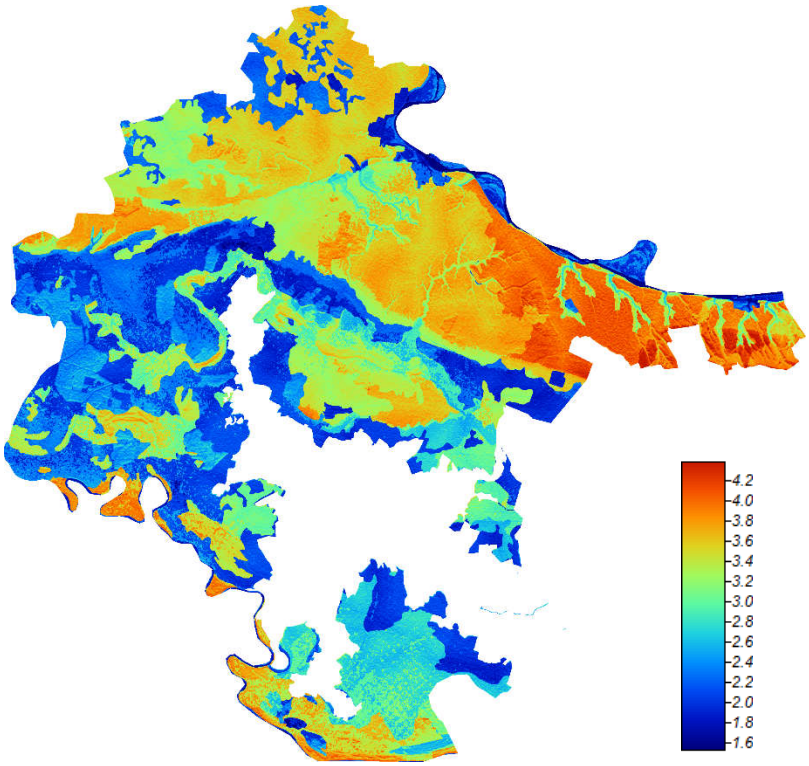
Tablica 8. Težine faktora određene metodom matrice usporedbe parova

Faktor	Težina grupe	*Udjel težine u grupi*	Pojedinačna težina
Nadmorska visina	0,4974	*65%*	0,33
Insolacija		*20%*	0,10
Izloženost vjetru		*15%*	0,07
Najniža temperatura siječanj	0,1082	*30%*	0,03
Srednja temperatura veljača		*30%*	0,03
Godišnja količina kiše		*40%*	0,05
Vrsta tla	0,3406		0,34
Udaljenost od prometnica	0,0538		0,05
UKUPNO	**100%**		**1,00**

Obrađene vrijednosti objedinjene su pomoću metode težinske linearne kombinacije. Prvi korak je, kao i u prethodnom primjeru, bilo određivanje pogodnosti za cijelo područje županije, a zatim su vrijednosti pogodnosti pomnožene sa slojem ograničenja tako da su ograničena područja eliminirana iz rezultata (slika 29.).

Najveća pogodnost za uzgoj lijeske na području Vukovarko-srijemske županije u trećem primjeru je na području Općine Ilok i neposredno uz njezinu zapadnu granicu (slika 29.), gdje pojedini pikseli postižu vrijednosti preko 4 (od maksimalnih 5).

Postoji visoka korelacija pogodnosti iz drugog i trećeg primjera, no razlika je u pouzdanosti kojom je ta pogodnost određena, obzirom da je u ovom slučaju postojala veća kontrola korisnika na cijeli postupak i manja mogućnost pogreške u slučaju drukčijih karakteristika ulaznih slojeva.

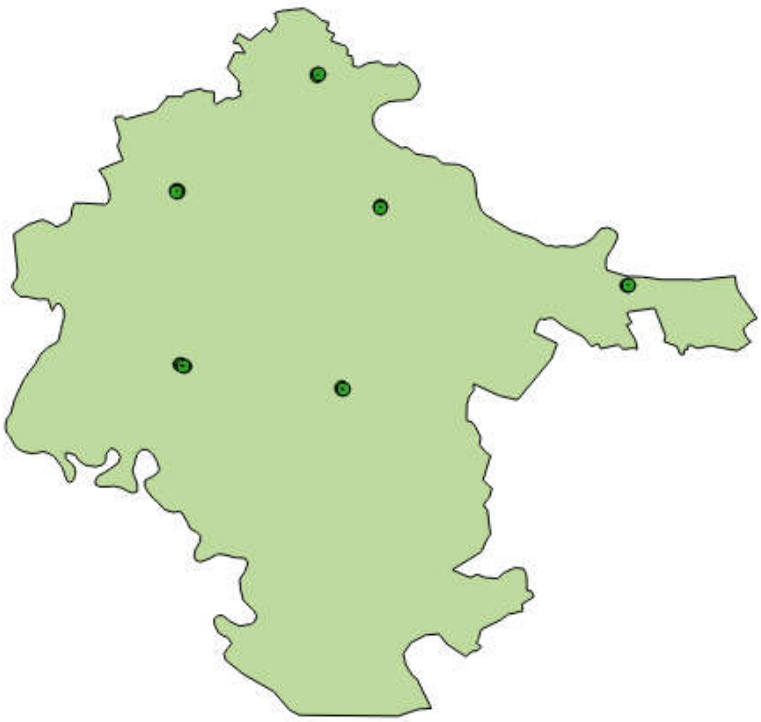


Slika 29. Konačni rezultat trećeg primjera multikriterijalne analize

4.3.5. Dodatne analize pomoću dobivenih rezultata pogodnosti multikriterijalnom analizom

Kako bi se stvorila poveznica između ovako dobivenih rezultata i stvarnog stanja na terenu, provedena je analiza izračunate pogodnosti uzgoja lijeske unutar poljoprivrednih čestica na kojima se u stvarnosti uzgaja lijeska. Takvim načinom usporedno se ocjenjuje razina iskorištenosti poljoprivrednih čestica za ovu specifičnu kulturu, ali se ujedno i provjeravaju rezultati multikriterijalne analize jer se očekuje da za većinu referentnih čestica pogodnost bude umjerena ili visoka.

Ručno pretraživanje poljoprivrednih čestica u ARKOD-u izvršeno je filtriranjem čestica s oznakom 422 (voćne vrste) i pretraživanjem domaćeg imena čestica koje ukazuje na prisutnost lijeske. Ukupno je pronađeno 6 poljoprivrednih čestica lijeske, ravnomjerno raspoređenih na području Vukovarsko-srijemske županije (slika 30.), s izuzetkom ograničenog područja na jugu općine (Spačvanski bazen). Nasadi lijeske na ortofotu imaju karakterističnu teksturu (slika 31.).



Slika 30. Prikaz položaja referentnih poljoprivrednih čestica lijeske u Vukovarsko-srijemskoj županiji



Slika 31. Primjer poljoprivredne čestice u ARKOD-u na kojoj se uzgaja lijeska

Rubne koordinate svih čestica su očitane u ARKOD-u i kreiran je vektorski sloj referentnih poljoprivrednih čestica lijeske. One su zatim preklopljene s rasterskim slojevima pogodnosti (iz sva tri primjera) te je dobivena prosječna pogodnost za svaku testnu česticu (tablica 9.). Sve testne čestice osim čestice u Gradištu, imaju umjerenu ili visoku vrijednost pogodnosti, najviše čestica na širem području Općine Ilok, gdje je i na širem području odmah

uočena najveća pogodnost za uzgoj lijeska na cijelom području županije. Relativni odnosi između pogodnosti čestica za drugi i treći primjer su podjednake.

Tablica 9. Podaci o testnim poljoprivrednim česticama lijeske u Vukovarsko-srijemskoj županiji

ARKOD šifra	Domaće ime	Općina	Pogodnost (druga)	Pogodnost (treća)
1434081	LJEŠNJAK	Trpinja	47,62	3,45
1440202	BLATO LIJESKA	Jarmina	49,32	3,47
1975763	LIJESKA - VEĆA	Gradište	24,21	2,09
3355192	LJEŠNJAK	Otok	41,13	3,29
2077019	LJEŠNJACI	Vukovar	38,22	3,40
1953186	POLANICA-LJEŠNJAK	Ilok	56,86	3,94

Preklapanjem rasterskog sloja pogodnosti uzgoja lijeske s vektorskim slojem vektoriziranih općina moguće je dobiti prosječnu pogodnost po općinama (tablica 10.). Ova analiza prvenstveno ima značaj za statističke potrebe i inventarizaciju na razini županije, jer ima potencijal za bolje upravljanje zemljištem ukoliko bi se za svaku općinu dodali podaci vezani uz financije i infrastrukturu (npr. godišnji nameti po općinama). Kao što je ranije spomenuto, najveća je pogodnost na samom istoku županije (Tompojevci, Lovas, Negoslavci i Ilok).

Tablica 10. Pogodnost za uzgoj lijeska po općinama u Vukovarsko-srijemskoj županiji

Općina	Prosječna pogodnost
Tompojevci	3,69
Lovas	3,69
Negoslavci	3,59
Ilok	3,55
Jarmina	3,46
Bogdanovci	3,45
Nuštar	3,32
Gunja	3,23
Markušica	3,20
Tordinci	3,18
Trpinja	3,12
Vukovar	3,09
Tovarnik	3,07
Stari Jankovci	2,98
Borovo	2,97
Drenovci	2,91
Otok	2,74
Županja	2,65
Bošnjaci	2,63
Nijemci	2,60
Stari Mikanovci	2,59
Vinkovci	2,57
Vođinci	2,57
Cerna	2,56
Gradište	2,55
Ivankovo	2,53
Babina Greda	2,49
Privlaka	2,48
Andrijaševci	2,46
Vrbanja	2,33

5. ZAKLJUČAK

Multikriterijalna analiza prostornih podataka predstavlja moćan alat pri odlučivanju u poljoprivrednoj proizvodnji, postavljanjem određenih uvjeta s ciljem pronalaska najpogodnijeg područja u skladu s tim uvjetima. Mogućnosti korištenja multikriterijalne analize u poljoprivredi su mnoge, no stupanj njezine iskoristivosti ovisi o poznavanju predmeta analize i razini utjecaja različitih kriterija, stoga je važno provesti detaljno istraživanje predmeta analize. Važno je i prilikom analize sagledati problem iz više različitih perspektiva, prikupljajući podatke različite tematike koji imaju utjecaj na rezultat analize i implementirajući ih u analizu sa svrhom kvalitetnijeg rješenja.

Teoretski je dio definiran u vidu izvršavanja pojedinih postupaka koji su temelj multikriterijalne analize, ali korisnik je velikim dijelom slobodan sam dati svoj subjektivan doprinos u analizi i odabrati jednu od mnogih metoda za svaki korak. Također, korisniku je dostupan širok izbor metoda ovisno o željenoj detaljnosti i kvaliteti analize.

Što se tiče odabira GIS programa, logičan izbor za veliku većinu multikriterijalnih analiza predstavljaju programi otvorenog koda, odnosno QGIS, SAGA GIS i GRASS GIS, obzirom da komercijalni softveri ne donose značajnu prevagu u provođenju multikriterijalne analize. Također, navedeni GIS programi otvorenog koda dobro se međusobno nadopunjavaju i omogućavaju izvršavanje najkompleksnijih multikriterijalnih analiza te GIS operacija i analiza općenito.

Obzirom na relativno malen broj literaturnih navoda gdje se multikriterijalna analiza praktično primjenjuje u poljoprivredi (čak i multikriterijalna analiza prostornih podataka općenito, izuzev isključivo teoretskih članaka), čini se da su te metode nedovoljno iskorištene i ima mnogo prostora za razvoj i istraživanja. Zabilježeni su slučajevi kada korisnici odstupaju od pravila unutar nekog koraka multikriterijalne analize i izvršavaju promjene temeljene na subjektivnoj procjeni. To je vrlo slikovit primjer kako multikriterijalna analiza korisnika obvezuje s vrlo malo stvari i omogućava mu veliku slobodu i mogućnost da svoje znanje maksimalno iskoristi pri dobivanju konačnog rezultata.

Praktičan primjer multikriterijalne analize proveden je na jednostavan način, pri čemu je prednost dana načinima i mogućnostima obrade podataka unutar analize. Za konkretnu primjenu dobro je načiniti nekoliko verzija rezultata analize s različitim vrijednostima i težinama faktora te usporediti rezultate i uspostaviti odnos između rezultata i stvarnih podataka prikupljenih terenskim opažanjem.

POPIS LITERATURE

Chen J. (2014): GIS-based multi-criteria analysis for land use suitability assessment in City of Regina, Environmental Systems Research 2014, 3:13

Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., Wehberg, J., Wichmann, V., and Böhner, J. (2015): System for Automated Geoscientific Analyses (SAGA) v. 2.1.4, Geosci. Model Dev., 8, 1991-2007, doi:10.5194/gmd-8-1991-2015.

Eastman R. (1999). Multi-criteria evaluation and GIS. Chap. 35. In: Longley PA, Goodchild MF, Maguire DJ, Rhind DW (eds) Geographical information systems. Wiley, New York. pp. 493-502.

Estoque R. (2011): GIS-based Multi-Criteria Decision Analysis (in Natural Resource Management), University of Tsukuba

FMLC (2017): Što je to Geografski Informacijski Sustav (GIS)?, http://www.fmlc.com.hr/sto-to-geografski-informacijski-sustav-gis/ (16.09.2017.)

GIS People (2017): Expert multi-criteria analysis services, http://www.gispeople.com.au/geospatial-consulting/multi-criteria-analysis/ (09.09.2017.)

GRASS GIS (2017): GRASS GIS Overview, https://grass.osgeo.org/documentation/general-overview/ (06.09.2017.)

Jurišić M., Plaščak I. (2009): Geoinformacijski sustavi – GIS u poljoprivredi i zaštiti okoliša, Poljoprivredni fakultet Osijek

Kihoro i sur. (2013): Suitability analysis for rice growing sites using a multicriteria evaluation and GIS approach in great Mwea region, Kenya. SpringerPlus 2:265

Lapaine, M., Tutić, D. (2007): O novoj službenoj kartografskoj projekciji Hrvatske - HTRS96/TM, Kartografija i geoinformacije, Vol.6 No.izv. / spec. Lipanj 2007.

Moulis (2017): Uzgoj lješnjaka, http://moulis.hr/1/#edukacijskikutak (16.09.2017.)

OIKON (2012): Studija korištenja i zaštite mora i podmorja na području Splitsko-dalmatinske županije,

https://www.dalmacija.hr/Portals/0/docs/UOGospodarstvo/studija_marikultura_sdz_final.pdf (18.09.2017.)

QGIS (2017): Discover QGIS, https://www.qgis.org/en/site/about/ (06.09.2017.)

Rouse, J., R. Haas, J. Schell, D. Deering (1973): Monitoring Vegetation Systems in the Great Plains with ERTS, Treći ERTS simpozij, NASA: 309-317.

Saaty, T L (1980): The Analytic Hierarchy Process. New York: McGraw Hill.

Sarkar A., Ghosh A., Banik P. (2012): Multi-criteria land evaluation for suitability analysis of wheat: a case study of a watershed in eastern plateau region, India, Geo-spatial Information Science, 2014; Vol. 17, No. 2, 119–128

Singha C., Swain K. C. (2016): Land suitability evaluation criteria for agricultural crop selection: A review, Agricultural Reviews, 37 (2) 2016 : 125-132

Voogd H. (1983): Multi-criteria evaluation for urban and regional planning. London, Pion

Zavod za prostorno uređenje Primorsko-goranske županije (2009): Analiza prostornih mogućnosti za korištenje energije vjetra u Primorsko-goranskoj županiji, https://zavod.pgz.hr/docs/zzpuHR/documents/183/Original.pdf (18.09.2017.)

POPIS INTERNETSKIH IZVORA:

https://www.agroklub.com/sortna-lista/voce/lijeska-13/ Agroklub: Lijeska (08.09.2017.)

http://www.plantea.com.hr/lijeska/ Plantea: Lijeska (16.09.2017.)

http://www.visitvukovar-srijem.com/hr/zupanija/polozaj/ Turistička zajednica Vukovarsko-srijemske županije: Položaj (28.11.2017.)

http://www.vusz.hr/info/osnovni-podaci Vukovarsko-srijemska županija: Osnovni podaci (28.11.2017.)

https://www.worldweatheronline.com/ World Weather Online (21.09.2017.)

SAŽETAK

Korištenjem metode prostornog višekriterijskog odlučivanja (primjena višekriterijske analize u prostornom kontekstu gdje aliternative, kriteriji i drugi elementi postojećeg problema imaju eksplicitne prostorne dimenzije) prikazana je mogućnost izrade tematske karte pogodnosti uzgoj lijeske u različitim dijelovima Vukovarsko-srijemske županije. Utvrđeni su relevantni podaci o prostornim čimbenicima koji utječu na uzgoj lijeske, pri čemu je najveći značaj dan nadmorskoj visini terena i pogodnosti tla iz pedološke karte. Prikupljanje podataka obavljeno je iz odgovarajućih organizacija i s proizvodnih površina. Navedeni podaci pripremljeni su, standardizirani, objedinjeni i preklopljeni kako bi se dobila tematske karta pogodnosti uzgoja. Najveća pogodnost tla za uzgoj lijeske dobivena je na samom istoku Vukovarsko-srijemske županije (kao i Republike Hrvatske), u Općini Ilok i njezinoj neposrednoj blizini.

Ključne riječi: multikriterijalna analiza, lješnjak, Vukovarsko-srijemska županija

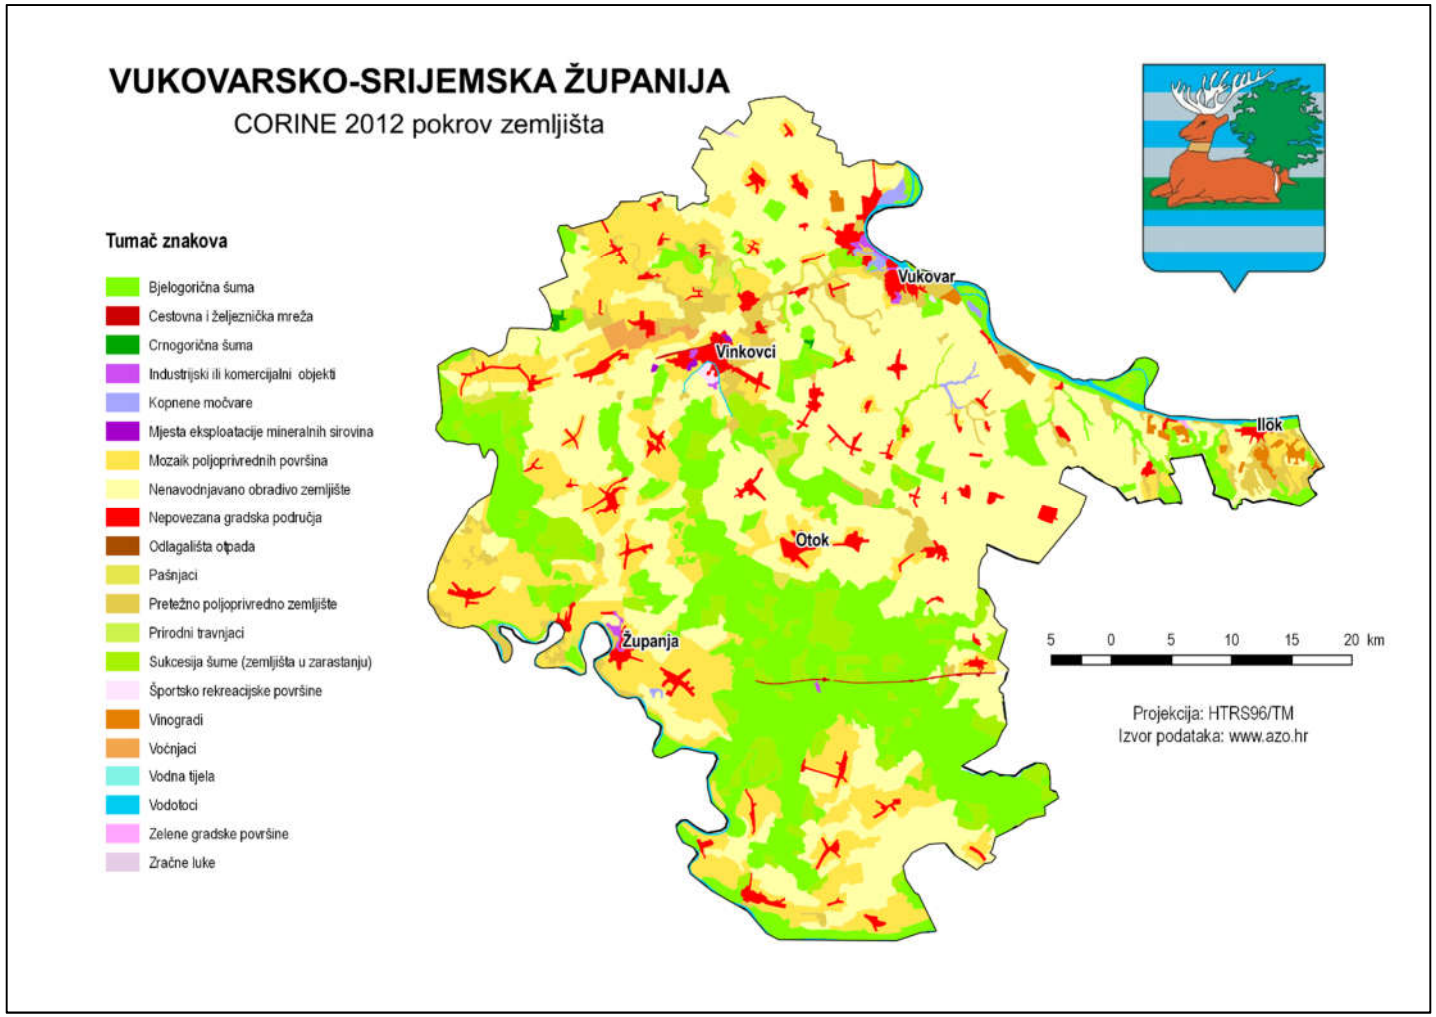
SUMMARY

Using the method of spatial multi-criteria decision making (application of multi-criteria analysis in a spatial context where alternatives, criteria and other elements of the existing problem have explicit spatial dimensions) the possibility of creating a thematic map of hazel cultivation suitability in different parts of Vukovarsko-srijemska County is presented. Information about relevant spatial data for hazel cultivation has been established. Highest importance is dedicated to terrain elevation and soil suitability from pedological map. The data collection was done from appropriate organizations and directly from the production areas. These data are prepared, standardized, unified and folded in order to obtain a thematic map of the hazel cultivation suitability. Best suitability results for hazel cultivation are on far east of Vukovarsko-srijemska County (also far east of Republic of Croatia), in Ilok Municipality and its direct surroundings.

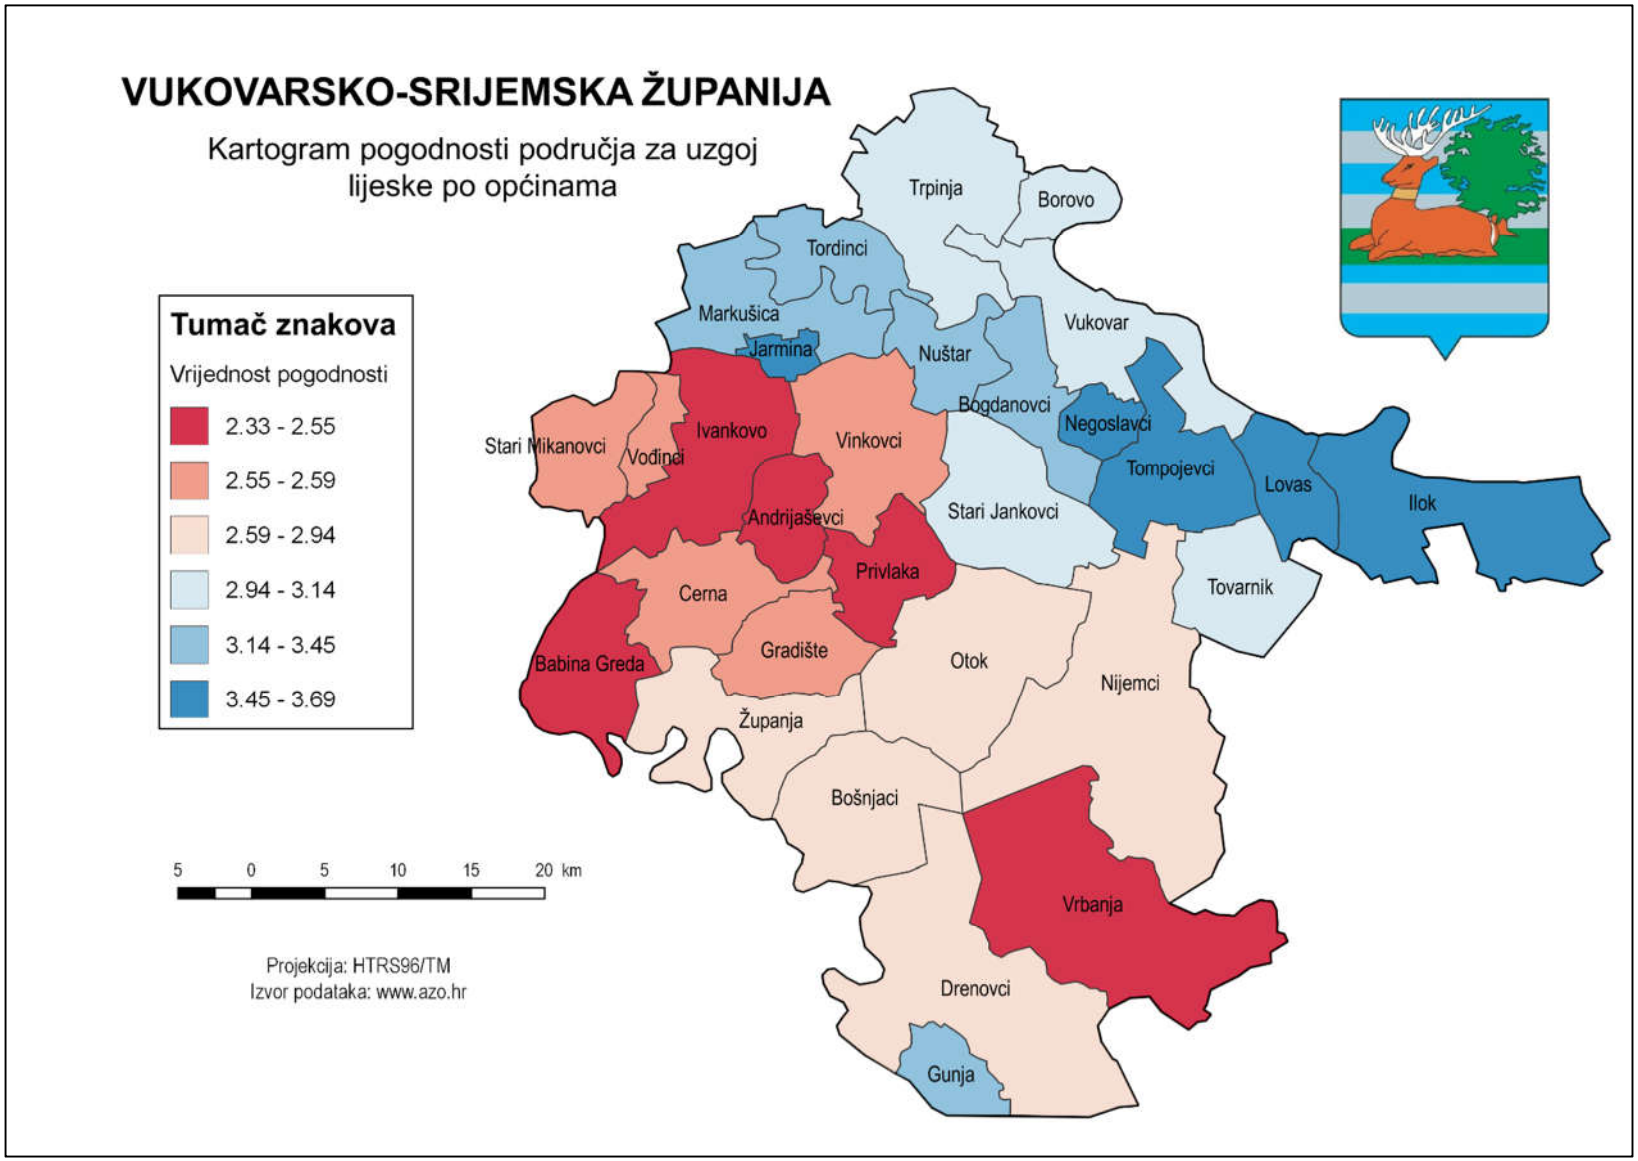
Key words: multicriteria analysis, hazel, Vukovarsko-srijemska County

PRILOZI

Prilog A: Kartografski prikazi obilježja Vukovarsko-srijemske županije

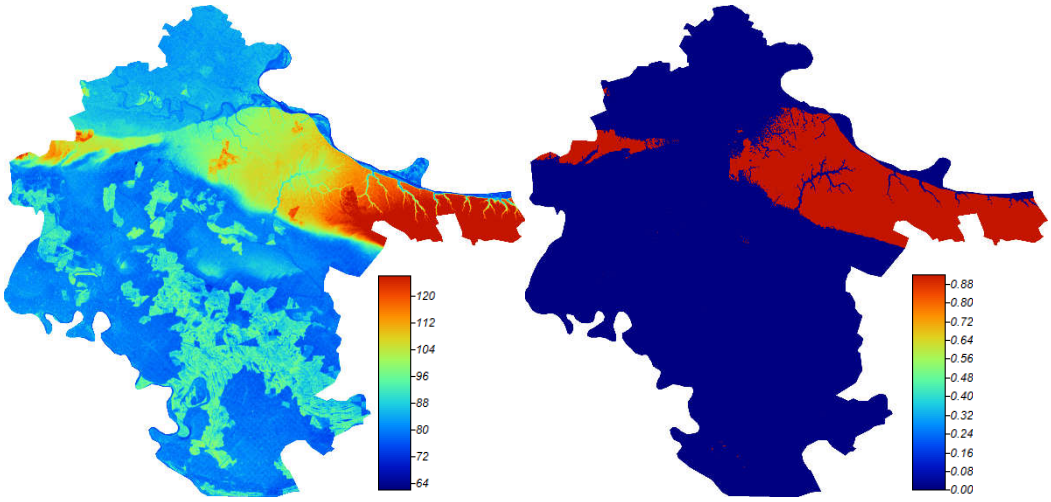


Slika 32. Pokrov zemljišta iz podataka CORINE 2012 za Osječko-baranjsku županiju

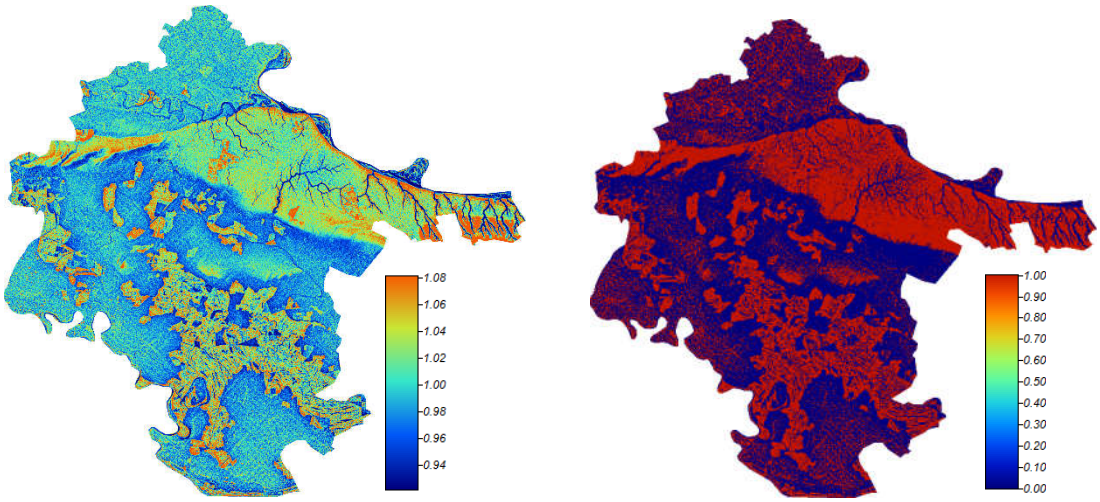


Slika 33. Kartogram pogodnosti po općinama Vukovarsko-srijemske županije

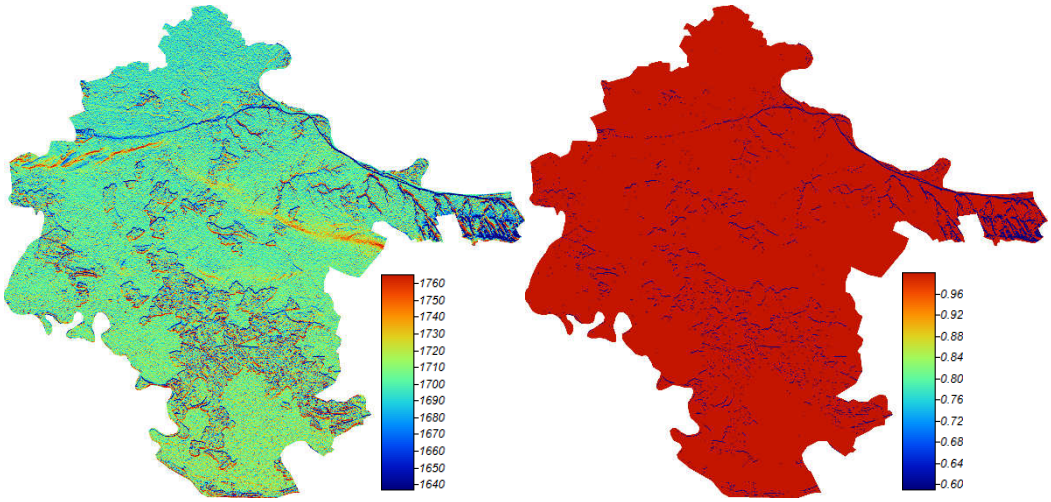
Prilog B: Prikazi vrijednosti faktora prije i poslije standardizacije (prvi primjer)



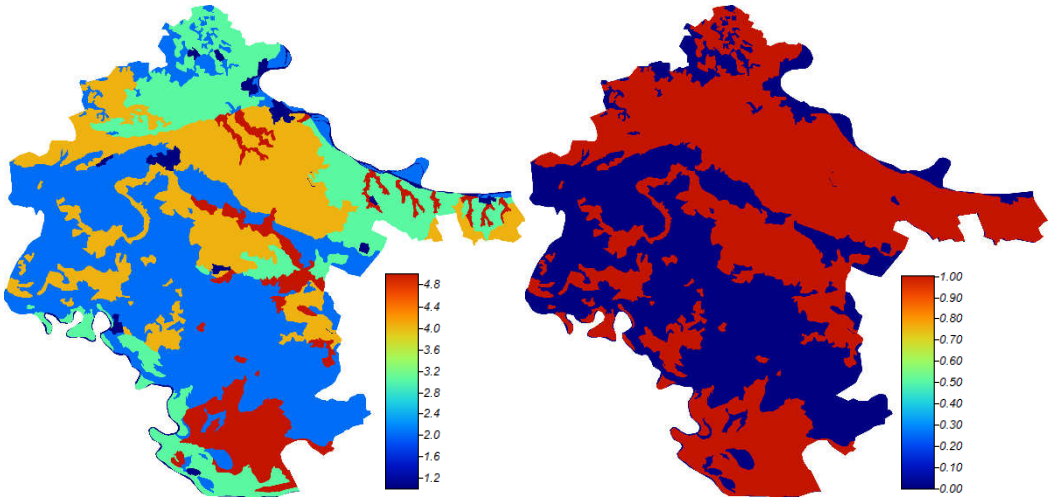
Slika 34. Digitalni model visina prije (lijevo) i poslije standardizacije (desno)



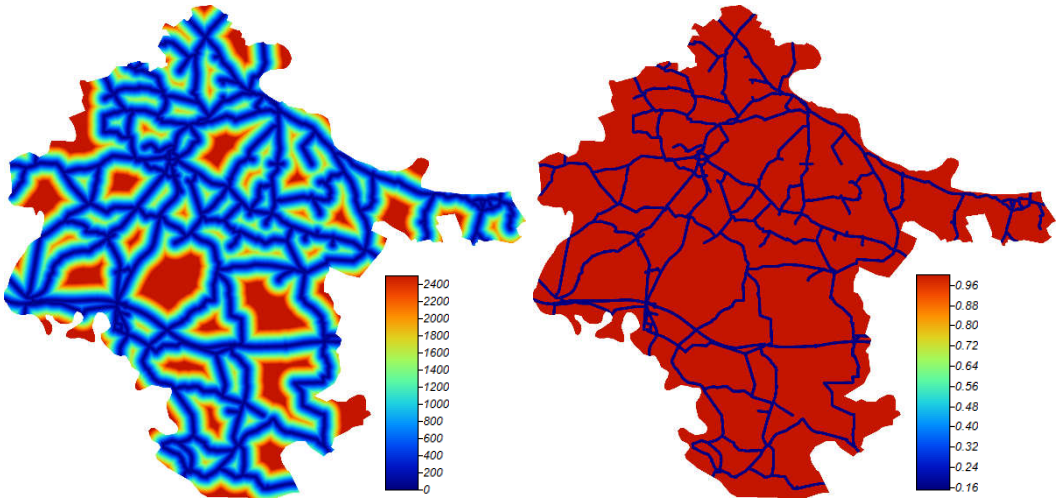
Slika 35. Izloženost vjetru prije (lijevo) i poslije standardizacije (desno)



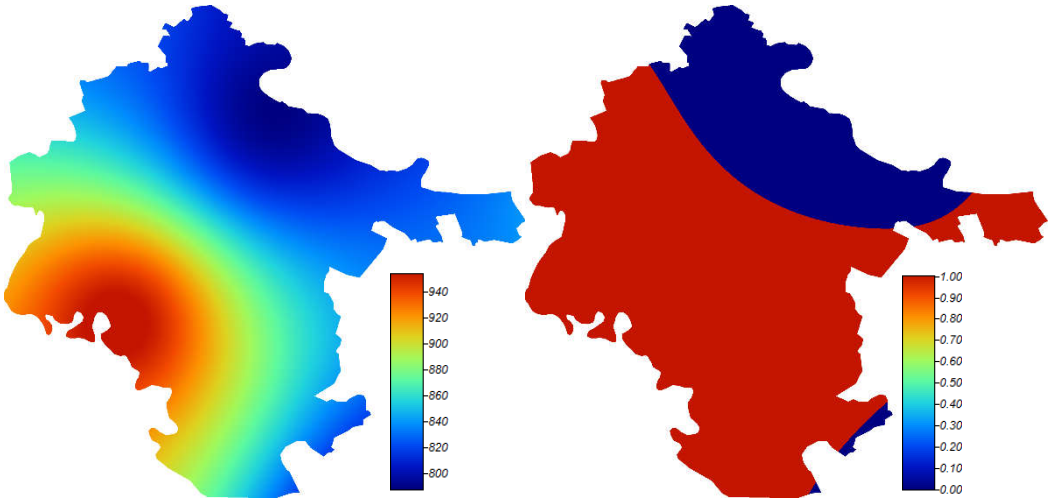
Slika 36. Insolacija prije (lijevo) i poslije standardizacije (desno)



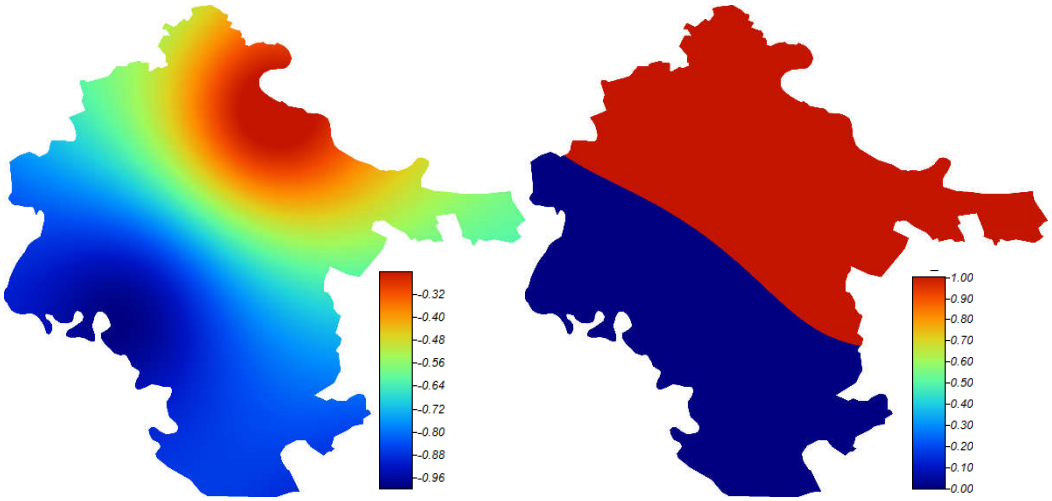
Slika 37. Pedološki podaci pogodnosti tla prije (lijevo) i poslije standardizacije (desno)



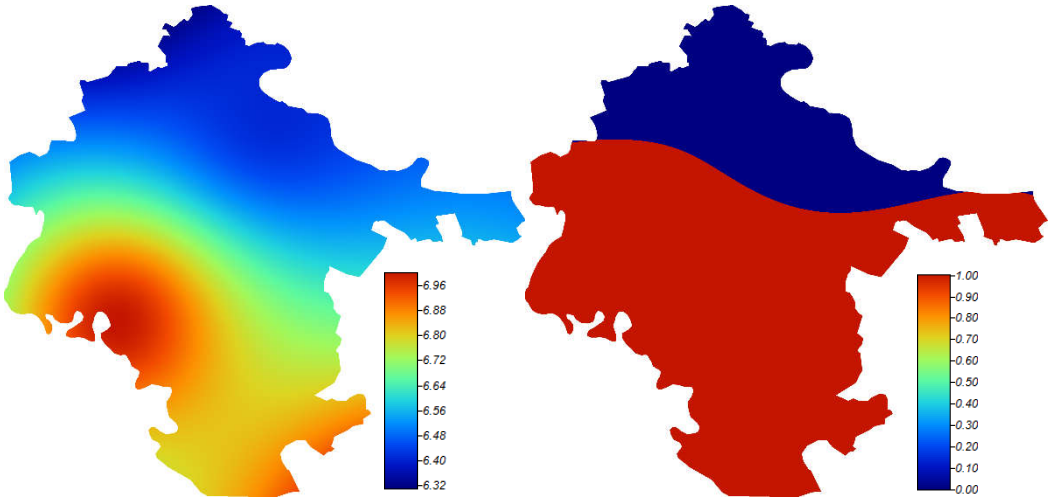
Slika 38. Udaljenost od cesta prije (lijevo) i poslije standardizacije (desno)



Slika 39. Ukupna godišnja količina kiše u mm prije (lijevo) i poslije standardizacije (desno)

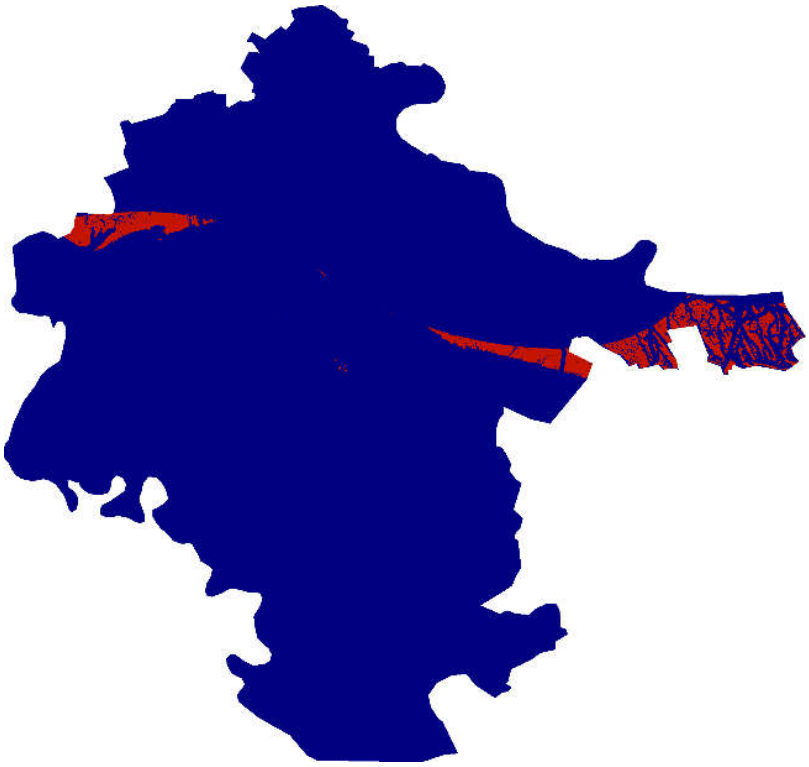


Slika 40. Prosječna dnevna najniža temperatura u siječnju u °C prije (lijevo) i poslije standardizacije (desno)

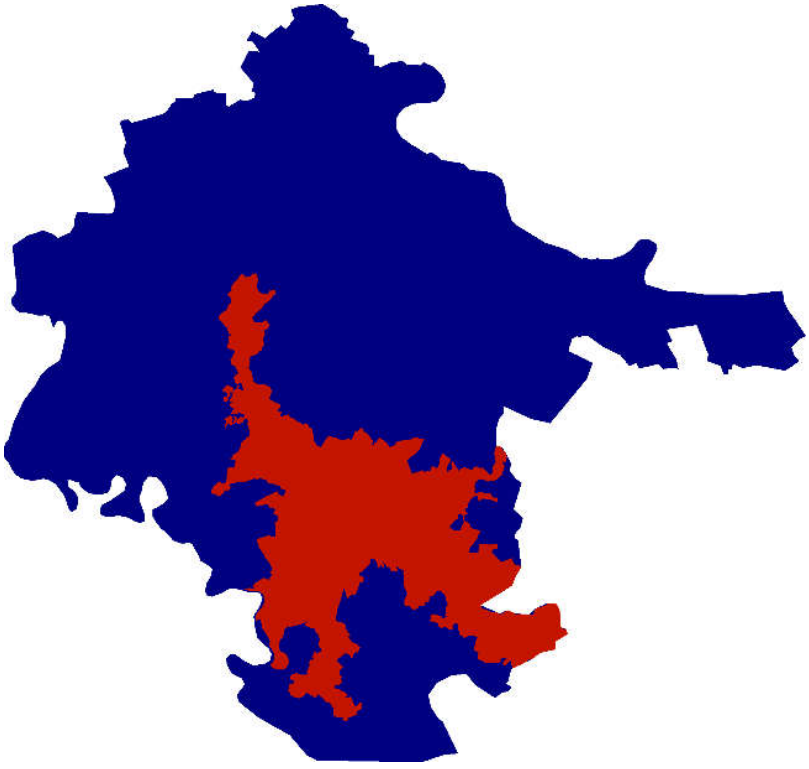


Slika 41. Prosječna dnevna srednja temperatura u veljači u °C prije (lijevo) i poslije standardizacije (desno)

Prilog C: Elementi korišteni u objedinjavanju podataka (prvi primjer)

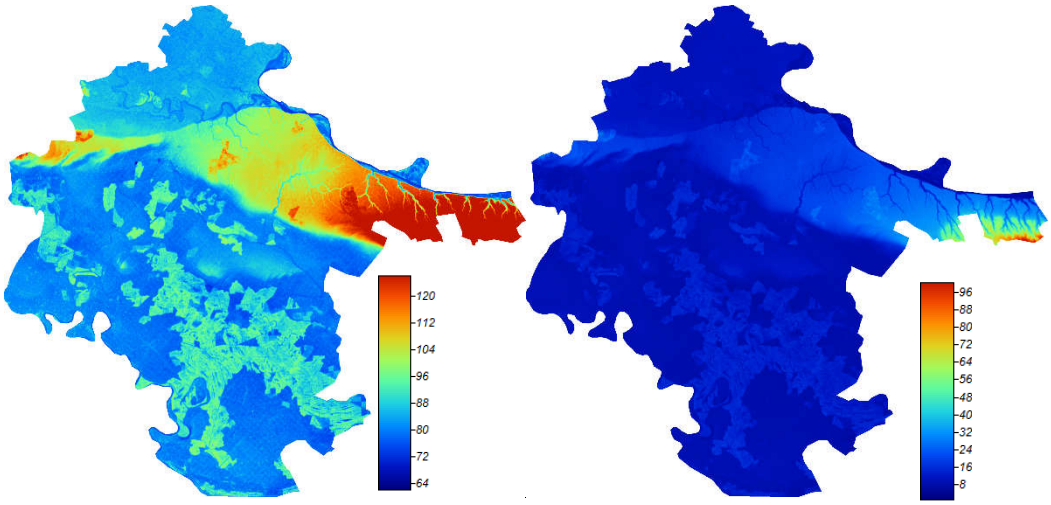


Slika 42. Umnožak standardiziranih vrijednosti i težina faktora (pogodnost) za cijelo područje županije (crveno – pogodno, plavo – nepogodno)

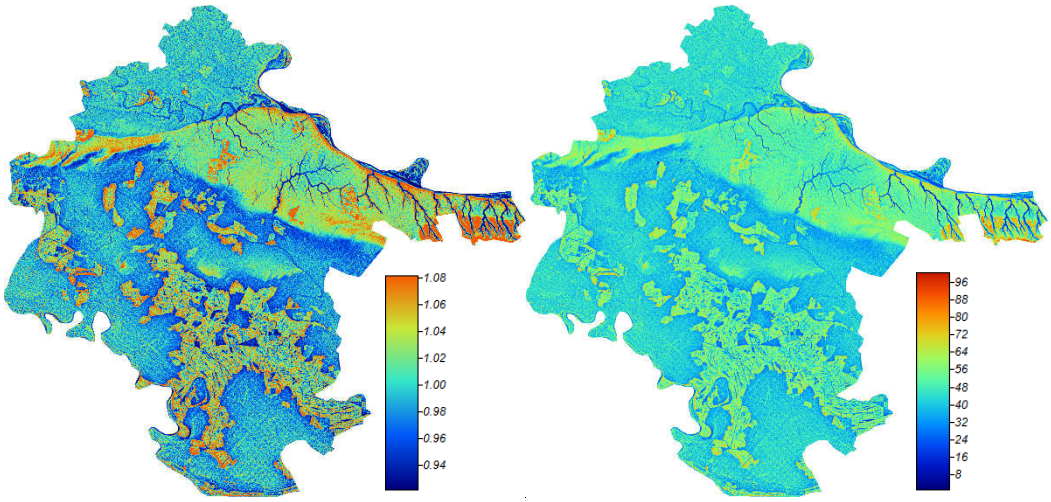


Slika 43. Raster ograničenja za područje županije (crveno – ograničenje, plavo – pogodno)

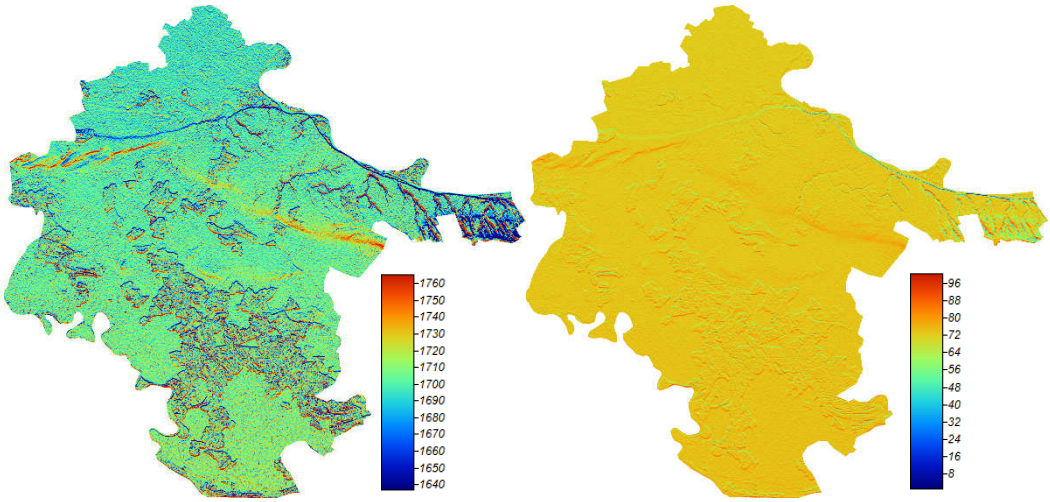
Prilog D: Prikazi vrijednosti faktora prije i poslije standardizacije (drugi primjer)



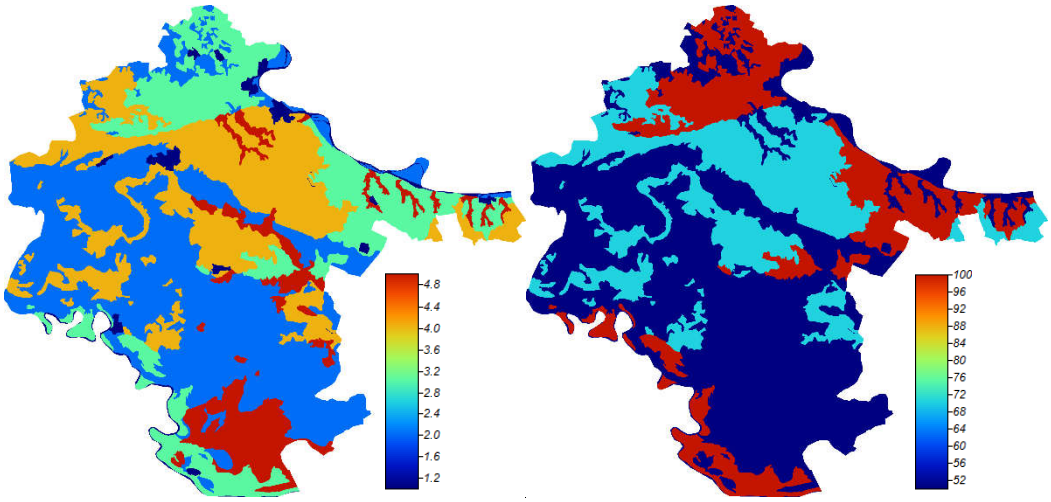
Slika 44. Digitalni model visina prije (lijevo) i poslije standardizacije (desno)



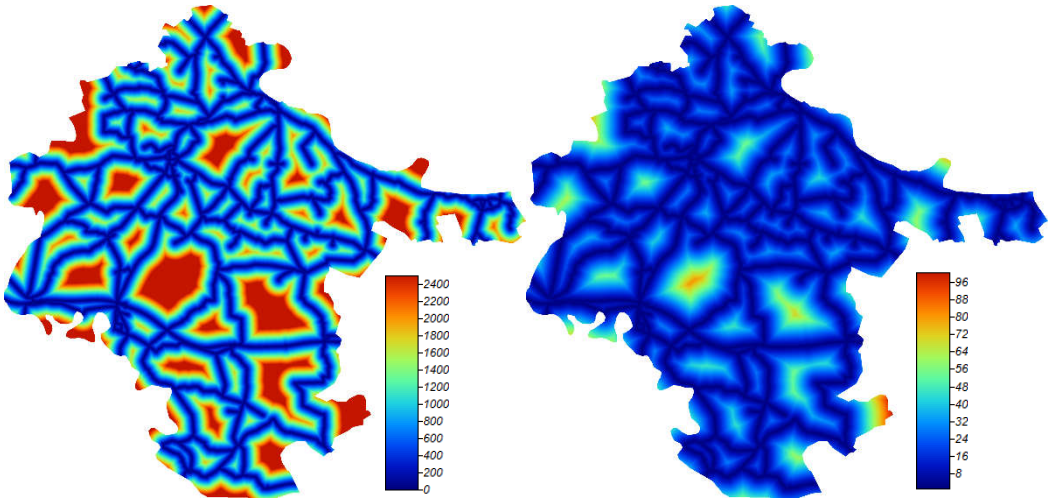
Slika 45. Izloženost vjetru prije (lijevo) i poslije standardizacije (desno)



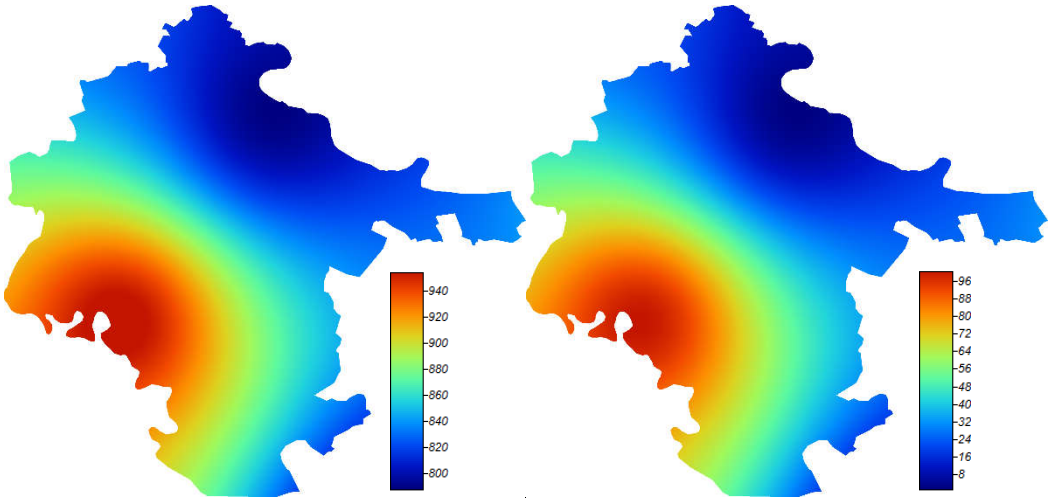
Slika 46. Insolacija prije (lijevo) i poslije standardizacije (desno)



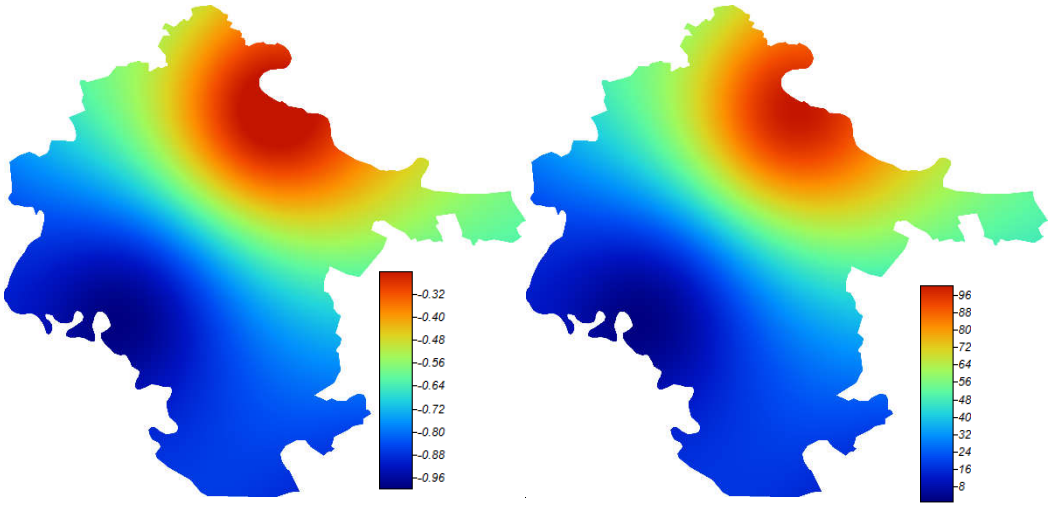
Slika 47. Pedološki podaci pogodnosti tla prije (lijevo) i poslije standardizacije (desno)



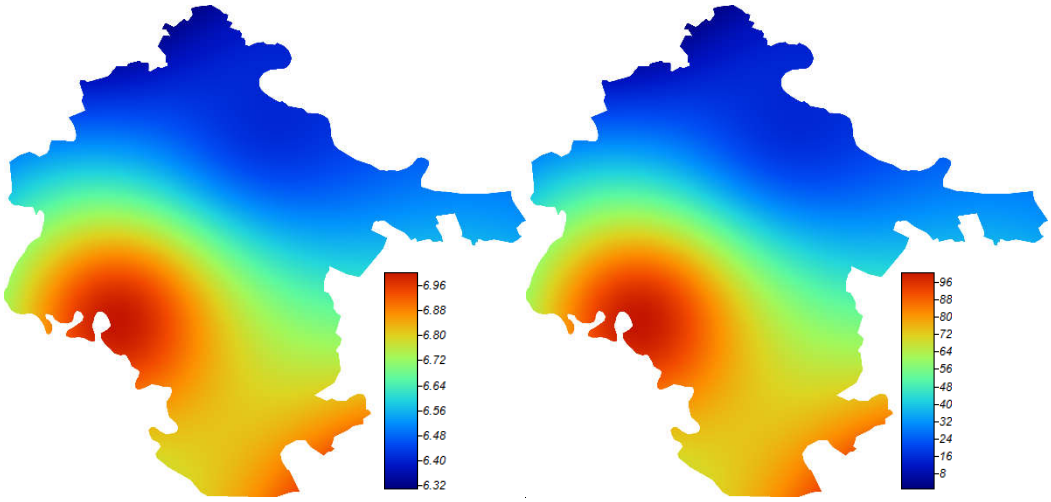
Slika 48. Udaljenost od cesta prije (lijevo) i poslije standardizacije (desno)



Slika 49. Ukupna godišnja količina kiše u mm prije (lijevo) i poslije standardizacije (desno)

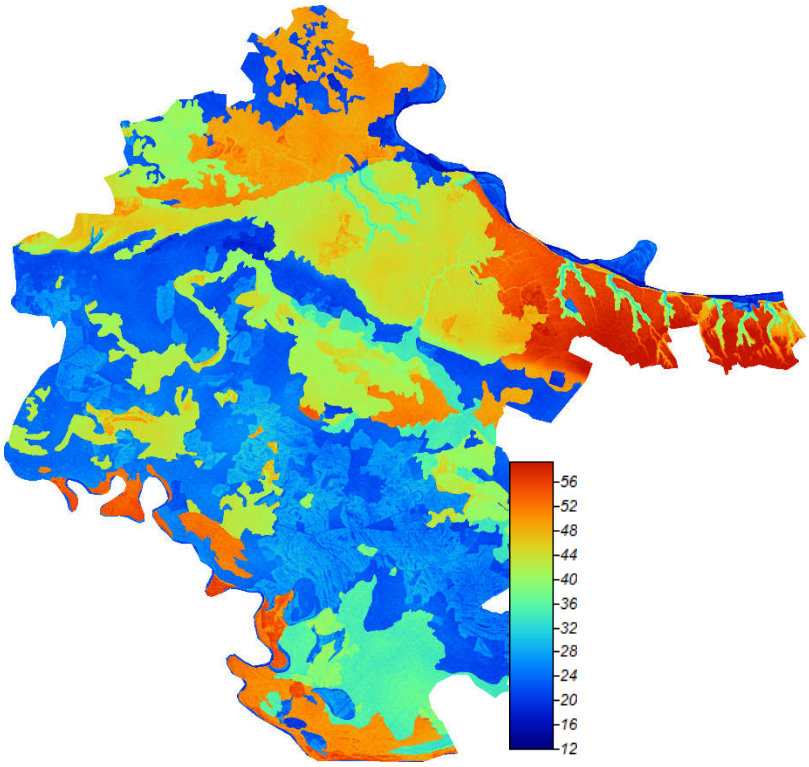


Slika 50. Prosječna dnevna najniža temperatura u siječnju u °C prije (lijevo) i poslije standardizacije (desno)

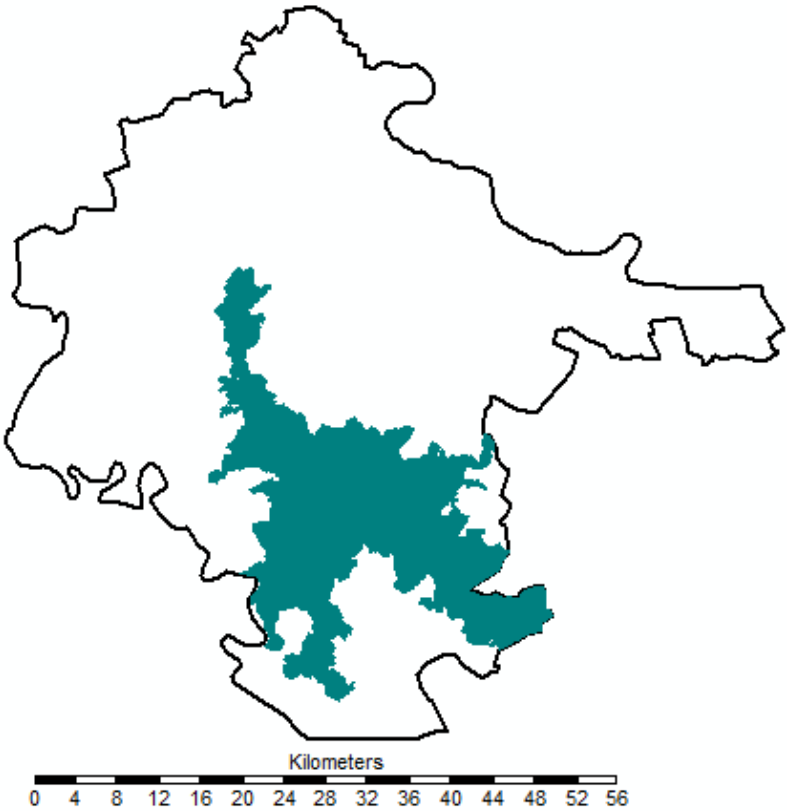


Slika 51. Prosječna dnevna srednja temperatura u veljači u °C prije (lijevo) i poslije standardizacije (desno)

Prilog E: Elementi korišteni u objedinjavanju podataka (drugi primjer)

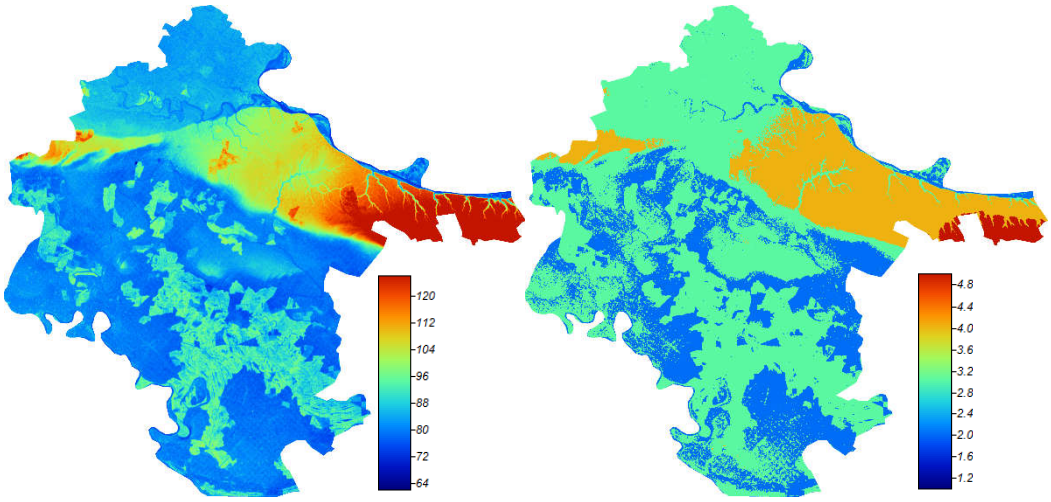


Slika 52. Umnožak standardiziranih vrijednosti i težina faktora (pogodnost) za cijelo područje županije

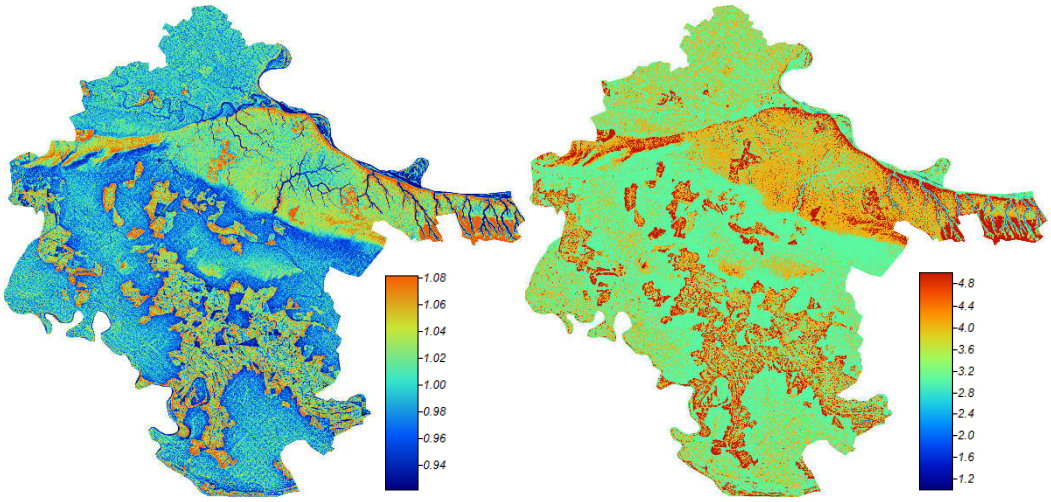


Slika 53. Raster ograničenja za područje županije (bijelo – pogodno, plavo – ograničenje)

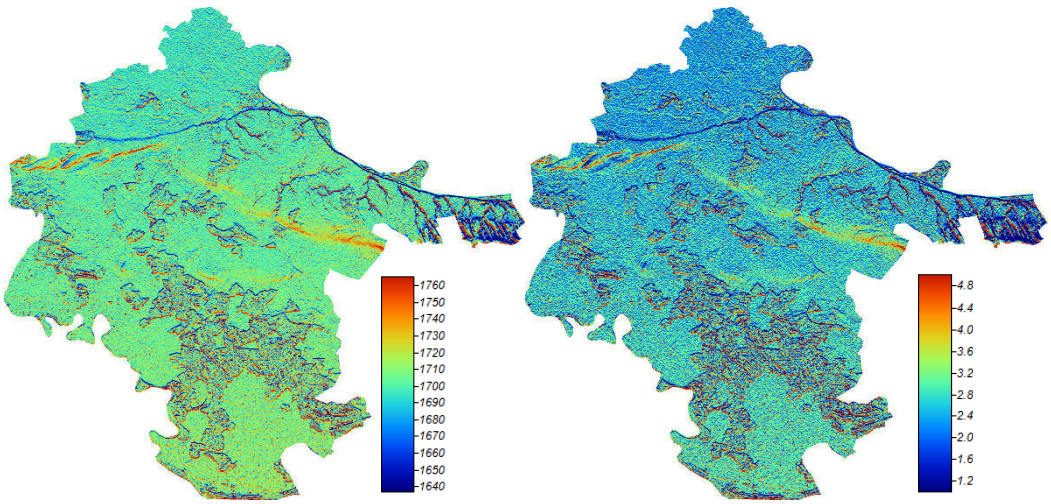
Prilog F: Prikazi vrijednosti faktora prije i poslije standardizacije (treći primjer)



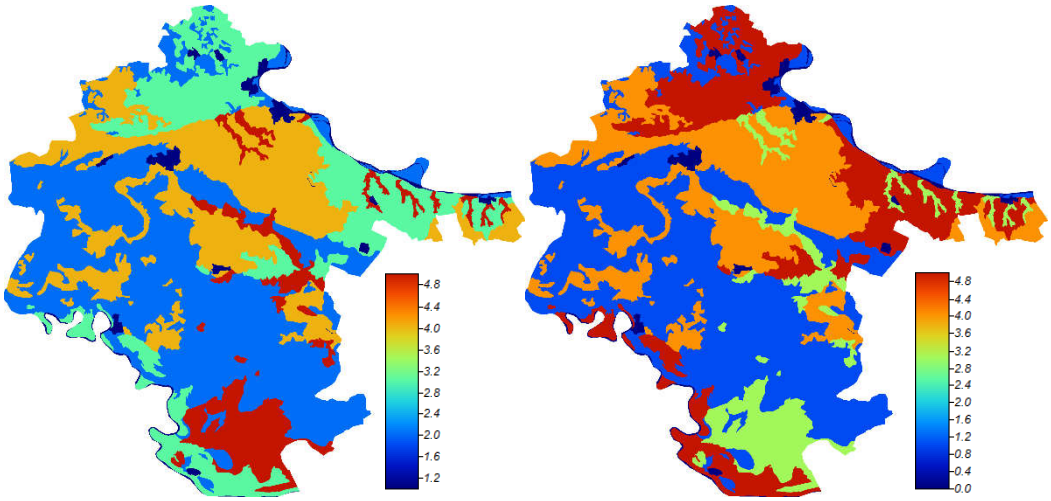
Slika 54. Digitalni model visina prije (lijevo) i poslije standardizacije (desno)



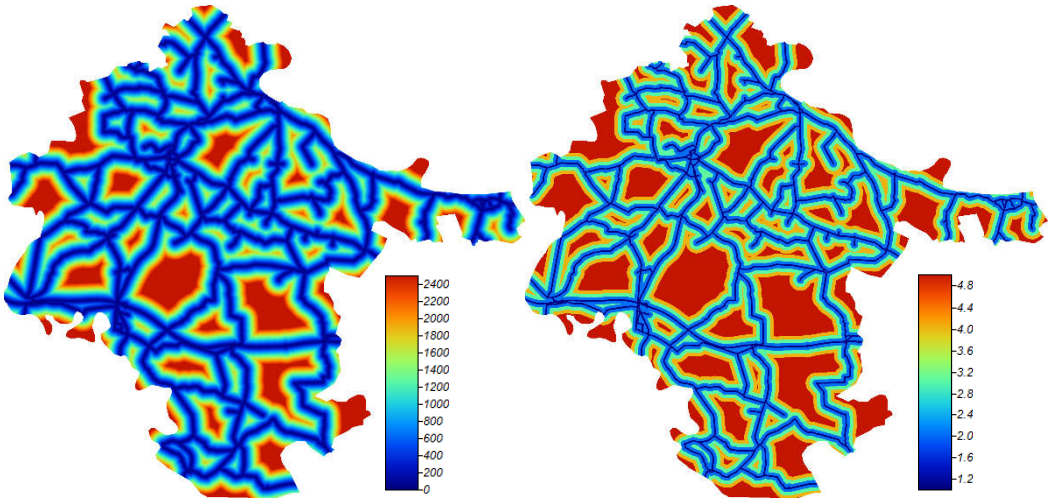
Slika 55. Izloženost vjetru prije (lijevo) i poslije standardizacije (desno)



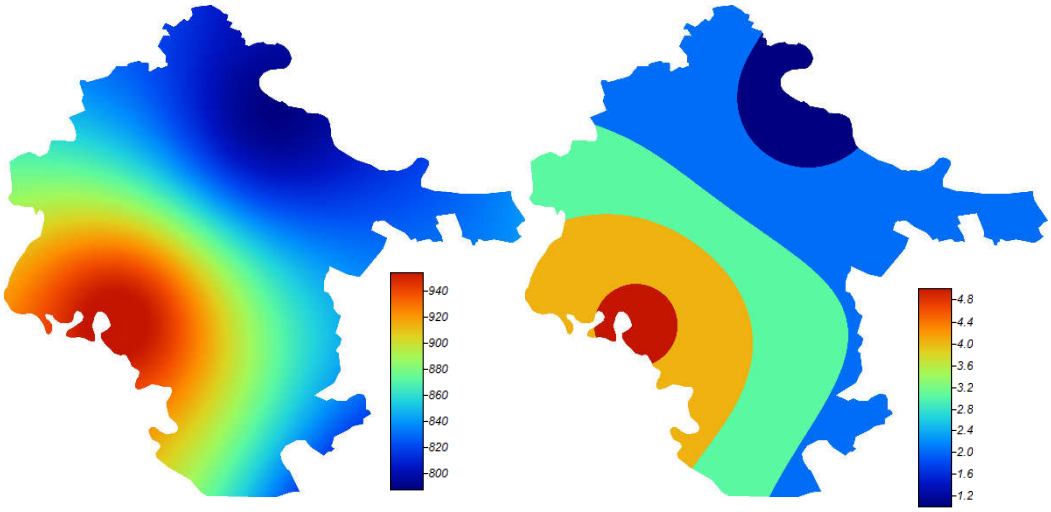
Slika 56. Insolacija prije (lijevo) i poslije standardizacije (desno)



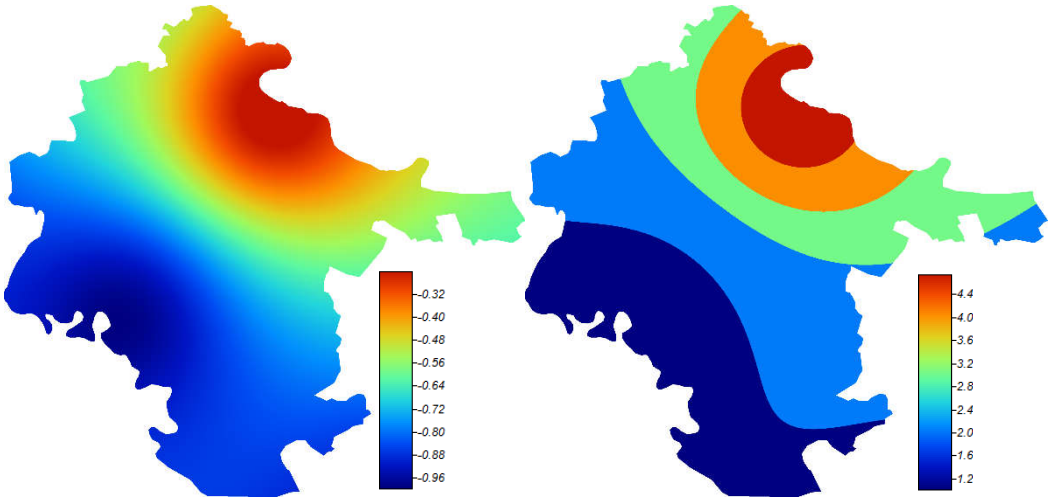
Slika 57. Pedološki podaci pogodnosti tla prije (lijevo) i poslije standardizacije (desno)



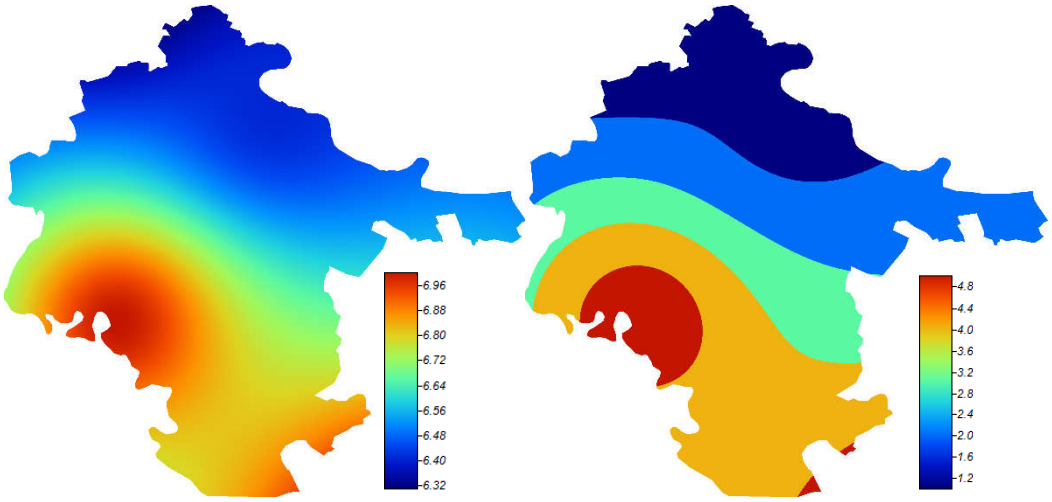
Slika 58. Udaljenost od cesta prije (lijevo) i poslije standardizacije (desno)



Slika 59. Ukupna godišnja količina kiše u mm prije (lijevo) i poslije standardizacije (desno)

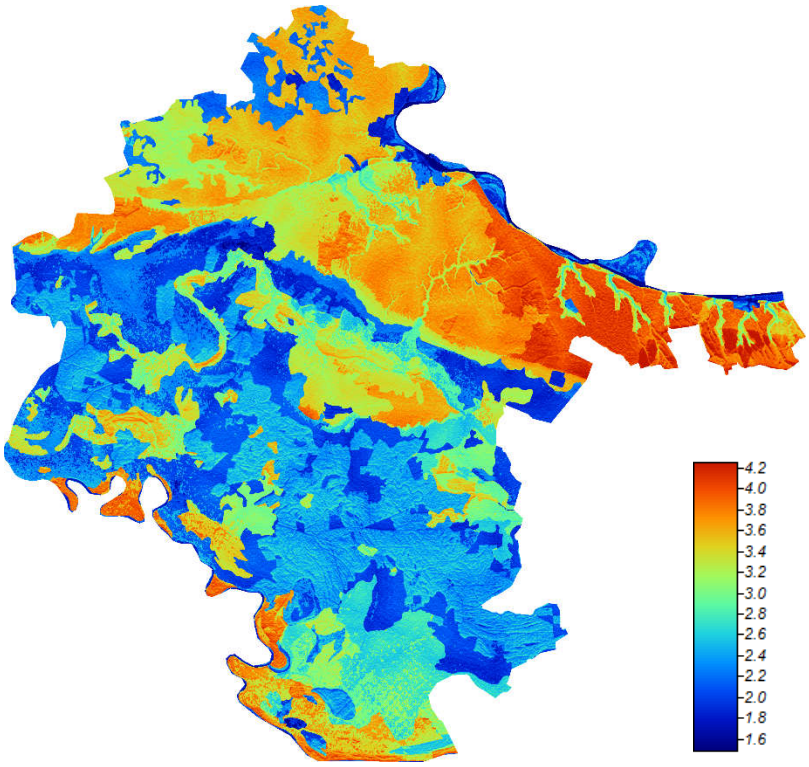


Slika 60. Prosječna dnevna najniža temperatura u siječnju u °C prije (lijevo) i poslije standardizacije (desno)

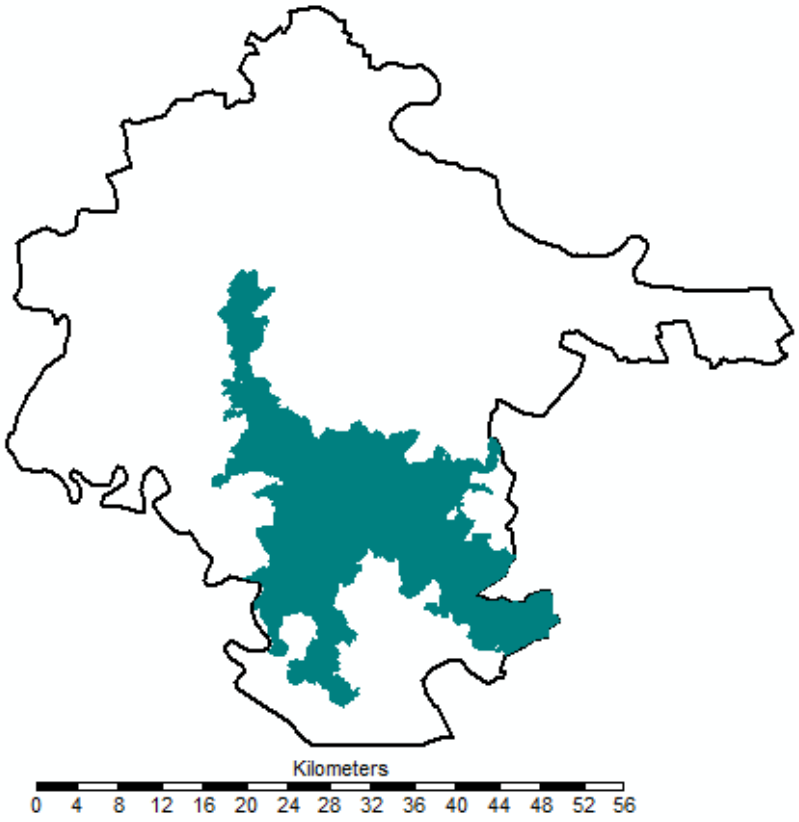


Slika 61. Prosječna dnevna srednja temperatura u veljači u °C prije (lijevo) i poslije standardizacije (desno)

Prilog G: Elementi korišteni u objedinjavanju podataka (treći primjer)



Slika 62. Umnožak standardiziranih vrijednosti i težina faktora (pogodnost) za cijelo područje županije



Slika 63. Raster ograničenja za područje županije (bijelo – pogodno, plavo – ograničenje)

POPIS TABLICA

Tablica 1. Prostorni kriteriji multikriterijalne analize pogodnosti uzgoja lijeske 32

Tablica 2. Kategorije pogodnosti u korištenoj pedološkoj karti..... 33

Tablica 3. Standardizacija vrijednosti kriterija u prvom primjeru..... 37

Tablica 4. Težine faktora u drugom primjeru multikriterijalne analize 39

Tablica 5. Kriteriji u trećem primjeru multikriterijalne analize 41

Tablica 6. Matrica usporedbe parova grupa faktora..... 43

Tablica 7. Normalizirana matrica usporedbe parova grupa faktora 43

Tablica 8. Težine faktora određene metodom matrice usporedbe parova..... 44

Tablica 9. Podaci o testnim poljoprivrednim česticama lijeske u Vukovarsko-srijemskoj županiji 47

Tablica 10. Pogodnost za uzgoj lijeska po općinama u Vukovarsko-srijemskoj županiji .. 48

POPIS SLIKA

Slika 1. Težine faktora pri određivanju pogodnosti područja za uzgoj riže na području pokrajina Kirinyaga, Embu i Mberee u Keniji (Kihoro i sur., 2013.) 7

Slika 2. Karta pogodnosti područja za uzgoj riže na području pokrajina Kirinyaga, Embu i Mberee u Keniji (Kihoro i sur., 2013.) 7

Slika 3. Karta pokrova zemljišta na području pokrajina Kirinyaga, Embu i Mberee u Keniji (Kihoro i sur., 2013.) 8

Slika 4. Raspodjela težina pri određivanju pogodnosti za uzgoj pšenice u porječju Beko u Indiji (Sarkar i sur., 2012.) 9

Slika 5. Karta područja pogodnosti za uzgoj pšenice u porječju Beko u Indiji (Sarkar i sur., 2012.) 9

Slika 6. Raspodjela težina pri određivanju prikladnosti uporabe zemljišta na području grada Regina u Kanadi (Chen, 2014.) 10

Slika 7. Karta prikladnosti uporabe zemljišta na području grada Regina u Kanadi (Chen, 2014.) 11

Slika 8. Usporedba prikladnosti uporabe zemljišta na području grada Regina u Kanadi (Chen, 2014.) 12

Slika 9. Potencijalne lokacije za gradnju vjetroelektrane u Primorsko-goranskoj županiji u studiji iz 2009. godine 13

Slika 10. Težine faktora pri multikriterijalnoj analizi određivanja pogodnosti za gradnju vjetroelektrane u Primorsko-goranskoj županiji u studiji iz 2009. godine 14

Slika 11. Pogodnosti idejnih lokacija za gradnju vjetroelektrane u Primorsko-goranskoj županiji u studiji iz 2009. godine 14

Slika 12. Rangiranje idejnih lokacija za gradnju vjetroelektrane u Primorsko-goranskoj županiji u studiji iz 2009. godine 15

Slika 13. Idejna (najpogodnija) lokacija Zebar za gradnju vjetroelektrane u Primorsko-goranskoj županiji u studiji iz 2009. godine 15

Slika 14. Područja koja zadovoljavaju postavljena ograničenja za kavezni uzgoj ribe u Splitsko-dalmatinskoj županiji iz studije 2014 16

Slika 15. Područja koja zadovoljavaju postavljena ograničenja za uzgoj školjkaša u Splitsko-dalmatinskoj županiji iz studije 2014..... 17

Slika 16. Prikaz temperature terena određene preko Landsat 8 termalnog kanala na dan 26.08.2017. kao faktora (lijevo) i ograničenja s graničnom vrijednosti 30°C (desno) 19

Slika 17. Prikaz cesta prije (lijevo) i poslije generalizacije (desno)..... 19

Slika 18. Stablo lijeske 28

Slika 19. Muški cvjetovi lijeske (rese)..... 29

Slika 20. Plod lijeske 29

Slika 21. Georeferenciranje prostornog plana Vukovarsko-srijemske županije..... 34

Slika 22. Kontrola kvalitete vektorizacije i georeferenciranja u odnosu na TK25 DGU ... 35

Slika 23. Meteorološke stanice korištene za interpolaciju (približno mjerilo 1:1 100 000)35

Slika 24. Podaci korištenih meteoroloških stanica 36

Slika 25. Rezultat prvog primjera multikriterijalne analize (crveno – pogodno, zeleno – nepogodno, plavo – ograničeno) 37

Slika 26. Računanje rezultata metodom težinske linearne kombinacije u SAGA GIS programu 39

Slika 27. Konačni rezultat drugog primjera multikriterijalne analize 40

Slika 28. Usporedba parova grupa faktora..... 42

Slika 29. Konačni rezultat trećeg primjera multikriterijalne analize..... 45

Slika 30. Prikaz položaja referentnih poljoprivrednih čestica lijeske u Vukovarsko-srijemskoj županiji..... 46

Slika 31. Primjer poljoprivredne čestice u ARKOD-u na kojoj se uzgaja lijeska..... 46

Slika 32. Pokrov zemljišta iz podataka CORINE 2012 za Osječko-baranjsku županiju.... 54

Slika 33. Kartogram pogodnosti po općinama Vukovarsko-srijemske županije..... 55

Slika 34. Digitalni model visina prije (lijevo) i poslije standardizacije (desno) 56

Slika 35. Izloženost vjetru prije (lijevo) i poslije standardizacije (desno)..... 56

Slika 36. Insolacija prije (lijevo) i poslije standardizacije (desno)..... 56

Slika 37. Pedološki podaci pogodnosti tla prije (lijevo) i poslije standardizacije (desno) . 57

Slika 38. Udaljenost od cesta prije (lijevo) i poslije standardizacije (desno) 57

Slika 39. Ukupna godišnja količina kiše u mm prije (lijevo) i poslije standardizacije (desno) 57

Slika 40. Prosječna dnevna najniža temperatura u siječnju u °C prije (lijevo) i poslije standardizacije (desno) 58

Slika 41. Prosječna dnevna srednja temperatura u veljači u °C prije (lijevo) i poslije standardizacije (desno) 58

Slika 42. Umnožak standardiziranih vrijednosti i težina faktora (pogodnost) za cijelo područje županije (crveno – pogodno, plavo – nepogodno) 59

Slika 43. Raster ograničenja za područje županije (crveno – ograničenje, plavo – pogodno) 59

Slika 44. Digitalni model visina prije (lijevo) i poslije standardizacije (desno) 60

Slika 45. Izloženost vjetru prije (lijevo) i poslije standardizacije (desno)..... 60

Slika 46. Insolacija prije (lijevo) i poslije standardizacije (desno)..... 60

Slika 47. Pedološki podaci pogodnosti tla prije (lijevo) i poslije standardizacije (desno) . 61

Slika 48. Udaljenost od cesta prije (lijevo) i poslije standardizacije (desno) 61

Slika 49. Ukupna godišnja količina kiše u mm prije (lijevo) i poslije standardizacije (desno) 61

Slika 50. Prosječna dnevna najniža temperatura u siječnju u °C prije (lijevo) i poslije standardizacije (desno) 62

Slika 51. Prosječna dnevna srednja temperatura u veljači u °C prije (lijevo) i poslije standardizacije (desno) 62

Slika 52. Umnožak standardiziranih vrijednosti i težina faktora (pogodnost) za cijelo područje županije..... 63

Slika 53. Raster ograničenja za područje županije (bijelo – pogodno, plavo – ograničenje) 63

Slika 54. Digitalni model visina prije (lijevo) i poslije standardizacije (desno) 64

Slika 55. Izloženost vjetru prije (lijevo) i poslije standardizacije (desno)..... 64

Slika 56. Insolacija prije (lijevo) i poslije standardizacije (desno)..... 64

Slika 57. Pedološki podaci pogodnosti tla prije (lijevo) i poslije standardizacije (desno) . 65

Slika 58. Udaljenost od cesta prije (lijevo) i poslije standardizacije (desno)..... 65

Slika 59. Ukupna godišnja količina kiše u mm prije (lijevo) i poslije standardizacije (desno) 65

Slika 60. Prosječna dnevna najniža temperatura u siječnju u °C prije (lijevo) i poslije standardizacije (desno) 66

Slika 61. Prosječna dnevna srednja temperatura u veljači u °C prije (lijevo) i poslije standardizacije (desno) 66

Slika 62. Umnožak standardiziranih vrijednosti i težina faktora (pogodnost) za cijelo područje županije..... 67

Slika 63. Raster ograničenja za područje županije (bijelo – pogodno, plavo – ograničenje) 67

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku **Diplomski rad**
Poljoprivredni fakultet u Osijeku
Sveučilišni diplomski studij, smjer Mehanizacija

Upotreba GIS-a u planiranju poljoprivredne proizvodnje – uzgoj lijeske

Marijan Deak

Sažetak:

Korištenjem metode prostornog višekriterijskog odlučivanja (primjena višekriterijske analize u prostornom kontekstu gdje alternative, kriteriji i drugi elementi postojećeg problema imaju eksplicitne prostorne dimenzije) prikazana je mogućnost izrade tematske karte pogodnosti uzgoj lijeske u različitim dijelovima Vukovarsko-srijemske županije. Utvrđeni su relevantni podaci o prostornim čimbenicima koji utječu na uzgoj lijeske, pri čemu je najveći značaj dan nadmorskoj visini terena i pogodnosti tla iz pedološke karte. Prikupljanje podataka obavljeno je iz odgovarajućih organizacija i s proizvodnih površina. Navedeni podaci pripremljeni su, standardizirani, objedinjeni i preklopljeni kako bi se dobila tematske karta pogodnosti uzgoja. Najveća pogodnost tla za uzgoj lijeske dobivena je na samom istoku Vukovarsko-srijemske županije (kao i Republike Hrvatske), u Općini Ilok i njezinoj neposrednoj blizini.

Rad je izrađen pri: Poljoprivredni fakultet u Osijeku

Mentor: doc.dr.sc. Ivan Plaščak

Broj stranica: 74

Broj grafikona i slika: 63

Broj tablica: 10

Broj literaturnih navoda: 24

Broj priloga: 7

Jezik izvornika: hrvatski

Ključne riječi: multikriterijalna analiza, lješnjak, Vukovarsko-srijemska županija

Datum obrane:

Stručno povjerenstvo za obranu:

1. prof.dr.sc. Mladen Jurišić, predsjednik
2. doc.dr.sc. Ivan Plaščak, mentor
3. Željko Barač, mag.ing.agr., član

Rad je pohranjen u: Knjižnica Poljoprivrednog fakulteta u Osijeku, Kralja Petra Svačića 1d.

BASIC DOCUMENTATION CARD

Josip Juraj Strossmayer University of Osijek **Graduate thesis**
Faculty of agriculture
University Graduate Studies, Mechanization

Use of GIS in agricultural production planning – hazel growing

Marijan Deak

Abstract:

Using the method of spatial multi-criteria decision making (application of multi-criteria analysis in a spatial context where alternatives, criteria and other elements of the existing problem have explicit spatial dimensions) the possibility of creating a thematic map of hazel cultivation suitability in different parts of Vukovarsko-srijemska County is presented. Information about relevant spatial data for hazel cultivation has been established. Highest importance is dedicated to terrain elevation and soil suitability from pedological map. The data collection was done from appropriate organizations and directly from the production areas. These data are prepared, standardized, unified and folded in order to obtain a thematic map of the hazel cultivation suitability. Best suitability results for hazel cultivation are on far east of Vukovarsko-srijemska County (also far east of Republic of Croatia), in Ilok Municipality and its direct surroundings.

Thesis performed at: Faculty of Agriculture in Osijek

Mentor: doc.dr.sc. Ivan Plaščak

Number of pages: 74

Number of figures: 63

Number of tables: 10

Number of references: 24

Number of appendices: 7

Original in: Croatian

Key words: multicriteria analysis, hazel, Vukovarsko-srijemska County

Thesis defended on date:

Reviewers:

4. prof.dr.sc. Mladen Jurišić, president
5. doc.dr.sc. Ivan Plaščak, mentor
6. Željko Barač, mag.ing.agr., member

Thesis deposited at: Library, Faculty of Agriculture in Osijek, Josip Juraj Strossmayer University of Osijek, Kralja Petra Svačića 1d.