Kvantitativne analize pogodnosti poljoprivrednog zemljišta Osječko-baranjske županije korištenjem geoprostornih tehnologija

Videković, Matej

Master's thesis / Diplomski rad

2019

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zadar / Sveučilište u Zadru**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:162:135217

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Image not found or type unknown *Repository / Repozitorij:*

University of Zadar Institutional Repository

zir.nsk.hr Image not found or type unknown

Sveučilište u Zadru

Odjel za geografiju

Diplomski sveučilišni studij primijenjene geografije (jednopredmetni)

Matej Videković

Kvantitativne analize pogodnosti poljoprivrednog zemljišta Osječko-baranjske županije korištenjem geoprostornih tehnologija

Diplomski rad

Zadar, 2019.

Sveučilište u Zadru

Odjel za geografiju

Diplomski sveučilišni studij primijenjene geografije (jednopredmetni)

Kvantitativne analize pogodnosti poljoprivrednog zemljišta Osječko-baranjske županije korištenjem geoprostornih tehnologija

Diplomski rad

Student/ica:

Matej Videković

Mentor/ica:

izv. prof. dr. sc. Ante Šiljeg

Zadar, 2019.

Izjava o akademskoj čestitosti

Ja, **Matej Videković,** ovime izjavljujem da je moj **diplomski** rad pod naslovom **Kvantitativne analize pogodnosti poljoprivrednog zemljišta Osječko-baranjske županije korištenjem geoprostornih tehnologija** rezultat mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na izvore i radove navedene u bilješkama i popisu literature. Ni jedan dio mojega rada nije napisan na nedopušten način, odnosno nije prepisan iz necitiranih radova i ne krši bilo čija autorska prava.

Izjavljujem da ni jedan dio ovoga rada nije iskorišten u kojem drugom radu pri bilo kojoj drugoj visokoškolskoj, znanstvenoj, obrazovnoj ili inoj ustanovi.

Sadržaj mojega rada u potpunosti odgovara sadržaju obranjenoga i nakon obrane uređenoga rada.

Zadar, 13. rujna 2019.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zadru

Odjel za geografiju Diplomski rad

KVANTITATIVNE ANALIZE POGODNOSTI POLJOPRIVREDNOG ZEMLJIŠTA OSJEČKO-BARANJSKE ŽUPANIJE KORIŠTENJEM GEOPROSTORNIH TEHNOLOGIJA

Matej Videković

Izvadak

Poljoprivreda, kao jedna od najstarijih gospodarskih grana, pratila je razvoj civilizacije od prapovijesti pa sve do danas. Povećanjem broja stanovnika došlo je do povećanja potrebe za hranom. Danas se teži proizvodnji što boljeg i kvalitetnijeg proizvoda da bi se zadovoljile potrebe potrošača. S ciljem postizanja željenih rezultata, potrebno je provoditi analize koje će pomoći pri vođenju i upravljanju resursima. Model pogodnosti poljoprivrednog zemljišta Osječko-baranjske županije za uzgoj ječma izrađen je višekriterijskim GIS analizama (MCDA-GIS) na temelju 10 odabranih kriterija: nadmorska visina, nagib, ekspozicija, tip tla, tekstura tla, pH tla, oborine, temperatura, ocjeditost i erozijski potencijal. Težinski koeficijenti kriterija određeni su metodom analitičkog procesa hijerarhije (AHP). Model je izrađen u računalnom programu *ArcMap 10.1* te su korištene njegove pojedine ekstenzije. Nakon što je model izrađen, reklasificiran je prema FAO metodologiji klasifikacije pogodnosti poljoprivrednog zemljišta u 5 klasa: S1, S2, S3, N1 i N2. Rezultati istraživanja pokazali su da je prostor Osječko-baranjske županije uglavnom umjereno pogodan (S2) za uzgoj ječma. Najveći utjecaj na klase pogodnosti imali su pedološki kriteriji. Također, najviše parcela zasijanih ječmom nalazi se u umjereno pogodnim (S2) klasama . Izrađeni NDVI indeks vegetacije također se preklapa s klasama pogodnosti i parcelama na kojima je zasijan ječam.

Ključne riječi: model pogodnosti, ječam, FAO klasifikacija, NDVI, MCDA-GIS, Osječko-baranjska županija

Voditelj: izv. prof. dr. sc. Ante Šiljeg

Povjerenstvo: prof. dr. sc. Željka Šiljković, doc. dr. sc. Denis Radoš, izv. prof. dr. sc. Nina Lončar (zamjenski član)

BASIC DOCUMENTATION CARD

University of Zadar

Department of Geography Graduation thesis

QUANTITATIVE ANALYSIS OF LAND SUITABILITY OF OSIJEK-BARANJA COUNTY USING GEOSPATIAL TECHNOLOGIES

Matej Videković

Abstract

Agriculture, as one of the oldest industries, has followed the development of civilization, from prehistoric times to the present. The increase in population has led to an increase in the need for food. Current effort is to produce the best quality product possible to meet the needs of consumers. In order to achieve desired results, analyses need to be conducted to help guide and manage the resources. The model of farmland suitability of Osijek-Baranja County for barley cultivation was made by using multicriteria GIS analyses (MCDA-GIS) based on 10 selected criteria: altitude, slope, aspect, soil type, soil texture, soil acidity, precipitation, temperature, drainage and erosion potential. The weighting coefficients of the criteria were determined by the Analytical hierarchy process (AHP). The model was created in ArcMap 10.1 and its individual extensions were used. After the model was created, it was reclassified according to the FAO methodology for classification of agricultural land suitability into 5 classes: S1, S2, S3, N1 and N2. The results of the study showed that the area of Osijek-Baranja County is generally moderately suitable (S2) for growing barley. Land suitability classes were most influenced by pedological criteria. Also, most parcels planted with barley are in moderately suitable (S2) classes. The constructed NDVI vegetation index also overlaps with the suitability classes and parcels where barley is sown.

Keywords: suitability model, barley, FAO classification, NDVI, MCDA-GIS, Osijek-Baranja County

Supervisor: Ante Šiljeg, PhD, Associate Professor

Reviewers: Željka Šiljković, PhD, Professor, Denis Radoš, PhD, Assistant Professor, Nina Lončar, PhD, Associate Professor (alternate member)

SADRŽAJ

PREDGOVOR 6
1. UVOD 7
2. OBJEKT I CILJ ISTRAŽIVANJA 8
HIPOTEZE RADA 8
3. PRETHODNA ISTRAŽIVANJA 9
4. TEORIJSKA OSNOVA RADA 12
4.1. JEČAM 12
4.1.1. Morfologija ječma 13
4.1.2. Agroekološki uvjeti ječma 13
4.1.3. Ječam u Hrvatskoj 14
4.1.4. Pivo i pivarski ječam 15
4.2. POLJOPRIVREDA U HRVATSKOJ 17
4.3. PODRUČJE ISTRAŽIVANJA 19
4.4. GEOPROSTORNE TEHNOLOGIJE U POLJOPRIVREDI 20
4.5. KVANTITATIVNE ANALIZE 23
4.5.1. Višekriterijske GIS analize 23
4.5.2. Proces analitičke hijerarhije (AHP) 25
4.5.3. Indeks zdravlja vegetacije 27
4.6. FAO KLASE POGODNOSTI ZEMLJIŠTA 29
5. METODOLOGIJA RADA 31
5.1. ANALIZA LITERATURE 32
5.2. PRIKUPLJANJE PODATAKA 32
5.3. ODREĐIVANJE KRITERIJA 34
5.3.1. Geomorfometrijski kriteriji 35
5.3.2. Pedološki kriteriji 38
5.3.3. Klimatski kriteriji 40
5.3.4. Hidrološki kriteriji 41
5.3.5. Ograničavajući faktori 43
5.4. STANDARDIZIRANJE KRITERIJA 45
5.5. ODREĐIVANJE TEŽINSKIH KOEFICIJENATA 49
5.6. AGREGIRANJE KRITERIJA 50
5.7. PROVJERA REZULTATA 52
5.7.1. Prvi pristup 52
5.7.2. Drugi pristup 54

6. MODEL POGODNOSTI – REZULTATI 56
6.1. VRLO POGODNA - S1 57
6.2. UMJERENO POGODNA – S2 59
6.3. MARGINALNO POGODNA – S3 60
6.4. TRENUTNO NEPOGODNA – N1 62
6.5. TRAJNO NEPOGODNA – N2 63
7. RASPRAVA 65
8. ZAKLJUČAK 68
9. LITERATURA 69
10. IZVORI 72
11. POPIS GRAFIČKIH PRILOGA 73
12. POPIS TABLIČNIH PRILOGA 74
13. SAŽETAK 75
14. SUMMARY 76

PREDGOVOR

Razvoj tehnologija omogućio je razvoj drugih djelatnosti. Brojne računalne tehnike počinju se primjenjivati u različitim djelatnostima. Tako posljednjih godina dolazi do sve veće upotrebe računalnih tehnologija u poljoprivredi jer one omogućavaju prikupljanje, spremanje, analiziranje, vizualiziranje i interpretiranje geopodataka. Zbog toga se nameće potreba za stvaranjem što kvalitetnijeg proizvoda kako bi se osigurala konkurentnost na tržištu. Upotreba visokotehnološke mehanizacije, GIS alata i svih ostalih suvremenih tehnologija, poljoprivredu čini modernom i sofisticiranom. U vezi s time pojavljuje se potreba za izradom modela pogodnosti poljoprivrednog zemljišta. S obzirom na to da se najviše koristi u prehrambenoj, tekstilnoj i pivarskoj industriji, ječam, a pogotovo ozimi ječam, dobiva na značaju u odnosu na stanje prijašnjih razdoblja. Izrađeni model ukazuje na umjerenu do visoku pogodnost poljoprivrednog zemljišta za uzgoj ječma na prostoru Osječko-baranjske županije. Također, bitno je naglasiti kako bi se ovakvi modeli mogli izrađivati za pojedine kulture, na mezo i mikro razini istraživanja, što bi u velikoj mjeri olakšalo upravljanje zemljištem i donošenje odluka poljoprivrednicima.

Zahvaljujem gospođi Silvi Wendling, pročelnici upravnog odjela za poljoprivredu Osječko-baranjske županije što mi je korisnim savjetima pomogla u dobivanju određenih informacija te što mi je omogućila kontakt s APPRRR-om.

Zahvale i *Agenciji za plaćanje u poljoprivredi, ribarstvu i ruralnom razvoju* (APPRRR) što su mi ustupili traženje podataka o parcelama na kojima je zasijan ječam na prostoru Osječko-baranjske županije.

Zahvale i kolegi Franu Domazetoviću koji mi je pomogao u izradi modela erozijskog potencijala na prostoru Osječko-baranjske županije te korisnim savjetima.

Naposljetku, zahvaljujem svom mentoru izv. prof. dr. sc. Anti Šiljegu koji mi je prenio svo potrebno znanje na diplomskom studiju i za sve korisne savjete koji su mi pomogli u izradi ovog diplomskog rada.

Ovaj rad izrađen uz potporu Hrvatske zaklade za znanost projektom Laboratorij za geoprostorne analize UIP-2017-05-2694.

1. UVOD

Od prošlosti pa do danas, poljoprivreda je bila jedna od najvažnijih sastavnica gospodarstva. Porastom stanovništva, porasla je i potražnja za hranom što je dovelo do toga da je poljoprivreda morala konstantno napredovati (Akinci i dr., 2013; Ennaji i dr., 2018). Zbog ubrzanog razvoj tehnologija, tehnika i njihove integracije u poljoprivredu, brojni autori navode kako su geoprostorne tehnologije (GIS, RS, GPS) postale nezamjenjiv alat u izradi analiza pogodnosti (Grubišić, 2014; Kazemi i Akinci, 2018; Zhang i dr. 2015; Akinci i dr. 2013). Višekriterijske analize (MCDA) predstavljaju alat koji omogućuje rješavanje kompleksnih problema gdje imamo više ponuđenih alternativa (Sekulić, 2019). U vezi s time, razvijaju se različiti koncepti, poput precizne poljoprivrede koja se temelji na integraciji novih tehnologija i poljoprivrednih strojeva u svrhu ostvarenja veće kvalitete i konkurentnosti (Jurišić i dr., 2015). U ovom radu izrađen je model pogodnosti poljoprivrednog zemljišta za uzgoj ječma u Osječko-baranjskoj županiji. Ječam je jedna od najstarijih ratarskih kultura čiji se počeci uzgoja pojavljuju na prostoru Bliskog istoka, 8000 godina pr. Kr. (Badr i dr., 2003). Zbog svoje hranjive vrijednosti, otpornosti na vanjske utjecaje te dobre prilagodljivosti, prepoznat je ne samo u proizvodnji stočne hrane, već i u farmaceutskoj, tekstilnoj i najvećim dijelom pivarskoj industriji (Martinčić i Kolak, 1993). U radu je objašnjeno 5 glavnih teorijskih sastavnica diplomskog rada: ječam, poljoprivreda, geoprostorne tehnologije, kvantitativne analize i FAO klasifikacija pogodnosti zemljišta. Model pogodnosti izrađen je primjenom višekriterijske GIS analize na temelju 5 grupa kriterija: geomorfometrijski (nadmorska visina, nagib, ekspozicija), pedološki (tip tla, tekstura tla, pH tla), klimatski (temperatura, oborine), hidrološki (ocjeditost i erozijski potencijal) te ograničavajući faktori. Kriteriji su standardizirani metodom donositelja odluka vrijednostima od 1 do 5 prema FAO klasama pogodnosti (Tablica 5), gdje su za svaku klasu određeni rasponi vrijednosti. Težinski koeficijenti izrađeni su metodom analitičkog procesa hijerarhije (AHP), gdje su najveće težinske koeficijente dobili pedološki kriteriji. Izrađeni model preklopljen je s ograničavajućim faktorima: šume, vode, prometnice, izgrađeno, trajni nasadi i travnate zajednice. Rezultati istraživanja ukazuju da su S2 klase pogodnosti najzastupljenije na prostoru Osječko-baranjske županije, izuzevši ograničavajuće faktore (Tablica 11). S obzirom na to da proizvodnja pivarskog ječma postaje sve aktualnija, javlja se potreba za oplemenjivanjem ječma i znanstvenim istraživanjima kako bi se ostvarili visokokvalitetni prinosi (Lalić i dr., 2007).

2. OBJEKT I CILJ ISTRAŽIVANJA

Objekt istraživanja ovog diplomskog rada su poljoprivredna zemljišta na području Osječko-baranjske županije s naglaskom na zemljišta pogodna za uzgoj ječma. Pogodnost zemljišta određena je prema FAO klasifikaciji pogodnosti koja se često koristi u izradi ovakvih modela i analiza (Ahamed i dr, 2000; Akinci i dr, 2013; Kazemi i Akinci, 2018; Sarkar i dr, 2014; Zhang i dr, 2015).

Cilj diplomskog rada je izrada modela vrednovanja poljoprivrednog zemljišta za uzgajanje ječma na prostoru Osječko-baranjske županije korištenjem geoprostornih višekriterijskih analiza (GIS-MCDA). Uzgajanje ječma, posebice pivarskog ječma, postaje sve prepoznatljivije u Republici Hrvatskoj te dolazi do povećanja površina zasijanih ječmom. Stoga se nameće potreba za izradom i opisivanjem modela pogodnosti koji će pridonijeti boljem razumijevanju trenutne stvarnosti, upravljanja zemljištem i u konačnici boljem uzgoju ječma. Potrebno je odrediti kriterije prema kojima će se vrednovati poljoprivredno zemljište i koji će biti standardizirani da bi se tim kriterijima mogli pridružiti odgovarajući težinski koeficijenti. Nakon toga se agregiraju kriteriji kako bi se izradio model pogodnosti zemljišta te na kraju slijedi provjera rezultata, odnosno ocjena izrađenog modela. Model se izrađuje na makro (metarske prostorne rezolucije) razini, za prostor Osječko-baranjske županije.

Sekundarni cilj je usporedba površine zasijane ječmom (za 2018. godinu) i kvantifikacija te površine prema klasama pogodnosti modela. Kako svaka klasa pogodnosti ima određena ograničenja u pogledu odabranih kriterija, potrebno je odrediti te površine zbog toga što prinosi poljoprivrednih kultura variraju od klase do klase.

HIPOTEZE RADA

1. hipoteza: Površine zasijane ječmom 2018. godine će biti preko 50 % u klasama pogodnosti izrađenog modela

2. hipoteza: Korištene metode daljinskih istraživanja pokazat će se kao efikasne metode u detekciji površina na kojima je zasijan ječam.

3. PRETHODNA ISTRAŽIVANJA

Proučavanje i vrednovanje poljoprivrednog zemljišta, posljednjih 20-tak godina bitno se promijenilo. Te su promjene uvjetovane razvojem tehnologija, računalnim programima, primjenom daljinskih istraživanja itd. Primjenom i intergracijom tih tehnologija (GPS, RS i GIS tehnologija) u poljoprivredi i mehanizaciji počinje se razvijati precizna poljoprivreda (Jurišić i dr., 2015). Takav pristup je sve zastupljeniji u modernoj poljoprivredi te se omogućuje brže stvaranja baze podataka, izrađivanja analiza, vrednovanja i upravljanja zemljištem (Jurišić i dr, 2015; Manić i dr., 2016). Prateći razvoj tehnologija, poljoprivreda i druge djelatnosti postaju sve sofisticiranije. U drugoj polovici 20. st. dolazi do razvoja različitih koncepata pa tako i koncepta višekriterijskog odlučivanja (GIS-MCDA) koje se prvi puta pojavljuje u djelatnostima poput krajobrazne arhitekture i prostornog planiranja (Malczewski i Rinner, 2015). Danas se taj koncept proširio na gotovo sve ljudske djelatnosti te postaje nezamjenjiv alat. Također, brojna znanstvena istraživanja vode se metodologijom višekriterijskog odlučivanja i primjenom geoprostornih tehnologija. S obzirom na navedeno, u nastavku su izneseni kratki pregledi znanstvenih radova koji su se vodili ovim metodologijama.

Ahamed i dr. (2000) se u radu *GIS-based fuzzy membership model for crop-land suitability analysis* bave izradom modela pogodnosti za uzgoj poljoprivrednih kultura na temelju AHP metode. Određuju 9 kriterija (8 pedoloških i 1 geomorfološki) kojima će vrednovati zemljište. Za određivanje klasa pogodnosti koristili su se FAO klasifikacijom iz 1976. godine. Nakon prikupljenih podataka, za standardizaciju kriterija koristili su se metodom *fuzzy membership*. Kao rezultat istraživanja dobili su pogodnost za usjev koji ima najveći potencijal.

Akinci i dr. (2013) u radu *Agricultural land use suitability analysis using GIS and AHP technique* određuju koja su zemljišta najbolja za poljoprivrednu uporabu Yusufeli okruga u Turskoj. Kriterije koje koriste u analizi su: tipovi tla, uporaba zemljišta, dubina tla, stupanj erozije, tekstura tla, nagib, nadmorska visina i ekspozicija. Određivanje težinskih koeficijenata izvršili su AHP metodom. Za izradu modela pogodnosti koristili su alat *Weighted Overlay* unutar programa *ArcGIS 9*. Izrađeni model je reklasificiran prema FAO klasama pogodnosti. Zaključak rada je bio da je tek 8 % površine područja istraživanja pogodno za poljoprivredno korištenje.

Ennaji i dr. (2018) bave se procjenom pogodnosti tla za poljoprivrednu proizvodnju u radu *GIS-based multicriteria land suitability analysis for sustainable agriculture in the northeast area of Tadla plain (Morocco)*. Na temelju 60 uzoraka tla, u radu su koristili 6 kriterija: pH, tekstura tla, udio organskog ugljika, slanost tla, CEC i nagib. Težinski koeficijenti su određeni metodom AHP-a, a za izradu modela pogodnosti koristili su *Weighted Overlay* unutar GIS okruženja. Završni model reklasificiran je u 4 klase: slaba, srednja, dobra i odlična klasa.

Feizizadeh i Blaschke (2013) u radu *Land suitability analysis for Tabriz County, Iran: a multi-criteria evaluation approach using GIS* istražuju optimalnu iskoristivost zemljišnih resursa u poljoprivrednoj proizvodnji. Za izradu modela koristili su 8 kriterija: nadmorska visina, nagib, ekspozicija, plodnost tla, pH, temperatura, oborine i površinske vode. Kriteriji su standardizirani od 0 do 1 metodom *fuzzy membership*. Težinski kriteriji određivani su AHP metodom, a završni model izrađen je alatom *Weighted Overlay*. U rezultatima istraživanja ukazuju da je 65 000 ha pogodno za navodnjavanje, a 120 000 ha za uzgoj na suho.

U radu *A land suitability model for rainfed farming by Multi-criteria Decision-making Analysis (MCDA) and Geographic Information System (GIS)*, Kazemi i Akinci (2018) analiziraju pogodnost tla provincije Golestan u Iranu korištenjem GIS-a i MCDM-a. Analiza je izrađena na temelju 10 kriterija: organski materijal, pH, EC, tekstura tla, temperatura, oborine, insolacija, nagib i nadmorska visina. U suradnji s lokalnim stručnjacima određeni su težinski koeficijenti kriterija unutar *Expert Choice* programa. Model je izrađen metodom *Weighted Overlay* te je reklasificiran prema FAO klasama pogodnosti. Rezultati su pokazali da je 56 % provincije pogodno za poljoprivrednu proizvodnju.

Mustafa i dr. (2011) u radu *Land suitability Analysis for Different Crops: A Multi Criteria Decision Making Approach using Remote Sensing and GIS* izrađuju model pogodnosti poljoprivrednog zemljišta za uzgoj različitih poljoprivrednih kultura (riža, kukuruz, pamuk, proso i dr.). Za izradu modela odabrali su 13 kriterija (kemijska svojstva tla, teksturu tla i nagib) kojima su težinski koeficijenti određeni AHP metodom. Tematske karte fizičkih i kemijskih svojstava tla izrađene su interpolacijskom metodom IDW (inverzna udaljenost). Nakon njihove standardizacije i određivanja težinskih koeficijenata, završni modeli izrađeni su metodom *Weighted Overlay* unutar *ArcGIS 9*. Modeli su reklasificirani prema FAO klasama pogodnosti zemljišta.

Sarkar i dr. (2014) u radu *Multi-criteria land evaluation for suitability analysis of wheat: a case study of a watershed in eastern plateau region, India* bave se izradom analiza pogodnosti zemljišta za poljoprivrednu uporabu korištenjem GIS-a i MCDA-a. Izrađeni model temelji se na 7 kriterija: dubina tla, ocjeditost, tekstura tla, nagib, pH, oborine i LULC. Kriteriji su standardizirani vrijednostima od 1 do 5 prema FAO klasama gdje 1 predstavlja klasu S1, 2 klasu S2 itd. AHP metoda korištena je za određivanje težinskih koeficijenata. Model je izrađen metodom *Weighted Overlay*. Rezultati istraživanja su pokazali da je područje istraživanja umjereno pogodno za uzgoj pšenice.

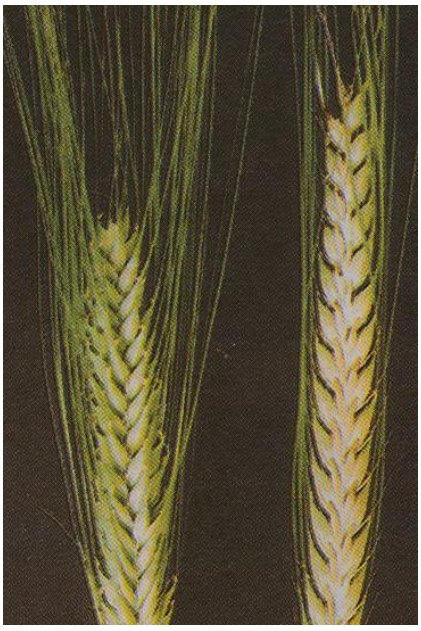
Yohannes i Soromessa (2018) su u radu *Land suitability assessment for major crops by using GIS-based multi-criteria approach in Andit Tid watershed, Ethiopia* izradili model pogodnosti zemljišta za uzgoj pšenice i ječma. Za izradu modela koristili su 18 kriterija: geomorfometrijske, pedološke, klimatske i društvene (udaljenost od rijeka i prometnica). Kriteriji su standardizirani metodom linearne skale, a težinski koeficijenti su određeni ANP metodom. Nakon standardizacije i određivanja težinskih koeficijenata kriterija, model je izrađen metodom *Weighted Overlay*. Rezultati istraživanja su pokazali jako slične rezultate pogodnosti zemljišta za pšenicu i ječam. Najvećim dijelom pogodnost je umjerena (oko 77 % površine istraživanja).

U radu *GIS based land suitability assessment for tobacco production using AHP and fuzzy set in Shandong province of China,* Zhang i dr. (2015) izradili su model pogodnosti zemljišta za uzgoj duhana. S obzirom na to da u Kini ima više od 300 milijuna pušača, duhanska industrija predstavlja jednu od najprofitabilnijih industrija, stoga joj se pridaje velika pažnja. Model pogodnosti zemljišta za uzgoj duhana izrađen je na temelju 20 kriterija (pedoloških, klimatskih i geomorfoloških). Za standardizaciju kriterija koristila se metoda *fuzzy membership* gdje su vrijednosti kriterija standardizirane od 0 do 1. Za određivanje kriterija koristila se metoda AHP gdje je tip tla imao najveći težinski koeficijent. Model je reklasificiran prema FAO klasama pogodnosti te su rezultati pokazali da je prostor istraživanja 29,82 % u klasi vrlo pogodno.

4. TEORIJSKA OSNOVA RADA

4.1. JEČAM

Ječam, jedna od najstarijih poljoprivrednih kultura, prvobitno se koristio za prehranu ljudi, a danas se uglavnom koristi za proizvodnju slada u industriji piva, u ishrani stoke (Martinčić i Kolak, 1993) te u farmaceutskoj i tekstilnoj industriji. Ječam potječe s prostora jugoistočne Azije, no kroz povijest njegovo stanište se mijenjalo kako i stanište ljudi. Vrste višerednog ječma potječu s prostora istočne Azije, a vrste dvorednog ječma s prostora Sirije i Palestine (Gagro, 1997). S obzirom na to da dvoredni ječam ima visoku hranidbenu vrijednost, u antici je služio kao hrana sportašima i gladijatorima, a u srednjem vijeku, budući da je pšenica bila skuplja, velik dio stanovništva koristio je ječam za pripremu kruha (URL 1). Među žitaricama, ječam ima najveći rasprostranjeni areal, od 10 do 70° sjeverne geografske širine, na nadmorskim visinama i preko 4 000 metara (Himalaje, Tibet, Ande), što potvrđuje njegovu visoku otpornost na nepovoljne uvjete uzgoja (Gagro, 1997). Od svih žitarica, ječam ima najkraće vegetacijsko razdoblje: kod jarog ječma ono je 55 do 130 dana, a kod ozimog 240 do 260 dana (Gagro, 1997). Što se tiče važnosti i upotrebe, ječam se pretežito koristi u hranidbi stoke, dodaje se u krmne smjese jer ima veliku hranidbenu vrijednost, dok se za prehranu ljudi koriste griz i pahuljice od ječma (Gagro, 1997). Koristi se u industriji piva i viskija jer daje visokokvalitetni slad, u farmaceutskoj i tekstilnoj industriji te za dobivanje ulja (Gagro, 1997).



Slika 1. Klas višerednog (lijevo) i dvorednog (desno) ječma (URL 1)

4.1.1. Morfologija ječma

Korijen ječma sastoji se od primarnog i sekundarnog korijena te ima žiličastu teksturu. Primarni korijen sastoji se od 4 do 8 korjenčića, dok je sekundarni slabije razvijen, stoga mu je moć upijanja smanjena (Gagro, 1997).

Stabljika ječma se sastoji od 5 do 7 koljenaca, manje je građevnih elemenata što je čini nježnijom i podložnijom polijeganju (Gagro, 1997). Ranije su sorte imale stabljiku i do 1,5 metara visine, no u novije vrijeme sorte imaju nižu stabljiku što smanjuje podložnost polijeganju te omogućuje gušću sjetvu (Gagro, 1997).

List je građen od lisnog rukavca i plojke gdje listovi obuhvaćaju stabljiku i prelaze jedan preko drugoga što ga značajno razlikuje od listova drugih žitarica (Gagro, 1997).

Klas je građen od koljenastog klasnog vretena i klasića gdje su klasići poredani jedan iznad drugog pa tako tvore red. S obzirom na razvoj klasića u usjeku klasnog vretena, ječam može biti dvoredni (ako se razvije jedan klasić) i višeredni (ako se razviju sva tri klasića) (Gagro, 1997). Prema broju redova na klasu, ječam se dijeli na dvoredni, prijelazni i višeredni ječam (Sl. 1).

Plod ječma je zrno sraslo s pljevicom. Sadrži 10-15 % bjelančevina, 70-75 % ugljikohidrata, 4–5 % celuloze i oko 2,5 % ulja i mineralnih tvari (Gagro, 1997). Masa tisuću zrna iznosi 30-40 grama, dok mu je hektolitarska težina od 60 do 70 kilograma (Gagro, 1997).

U novije vrijeme dolazi do upotrebe bespilotnih letjelica i laserskih senzora u poljoprivredi koje omogućuju izradu visokorezolucijskih snimaka i modela. Na taj način se mogu detektirati različiti usjeve prema njihovoj morfologiji.

4.1.2. Agroekološki uvjeti ječma

Ječam je relativno osjetljiv na niske temperature, no može izdržati temperature i do -20°C ako one kraće traju te je u odnosu na pšenicu i zob otporniji na toplinske udare. Da bi proklijao, minimalna temperatura je oko 1 – 2 °C, a optimalna temperatura za klijanje je oko 20°C (Gagro, 1997).

Što se tiče vode, ječmu su potrebne ravnomjerno raspoređene oborine, oko 450 mm, a s obzirom na to da mu je najviše vode potrebno u početku rasta i razvoja, sije se početkom

proljeća ili jeseni kada ima dovoljno vode (Gagro, 1997). Ako ječam nema dovoljno vode, to će utjecati na slabiji razvoj i rast, smanjeni prirod, a ako ječam ima višak vode, tada dolazi do smanjenja opskrbe kisikom i hranjivim tvarima (Gagro, 1997).

S obzirom na to da ima slabije razvijen korijen, ne podnosi tla loše kvalitete, tla velike kiselosti i tla na kojim se zadržava oborinska voda, stoga će pedološki kriteriji dobiti najveće ocjene pri određivanju težinskih koeficijenata. Potrebno je osigurati plodnije tlo, slabije kiselo do neutralno. Pjeskovita i vlažna tla ne pogoduju uzgoju ječma (Gagro, 1997). Tlo mora biti ocjedito, a optimalna kiselost iznosi 6,5 – 7,2 pH (URL 2). S obzirom na broj redova zrna, ječam ima oko 80 različitih sorti (URL 3).

Ozimi ječam sije se krajem rujna i početkom listopada. Nije ga pogodno sijati ranije jer tada ječam prebujan ulazi u zimu što ga može oštetiti (Gagro, 1997). Jari ječam sije se krajem siječnja i u veljači, kada ima dovoljno vremena za vegetaciju i kada se može najbolje iskoristiti zimska voda i slabiji intenzitet bolesti i nametnika (Gagro, 1997). Sije se sijačicom u redovima razmaka 8 – 10 cm, na dubini 3 – 4 cm, ovisno o tipu i vlažnosti tla. Može se sijati gušće kako bi se smanjio broj sekundarnih vlati što utječe na manje polijeganje. Za ozimi ječam preporučuje se 500 – 550 biljaka na m^2 (Gagro, 1997). Ječam se sije u plodoredu, a povoljne pretkulture su zrnate mahunarke, suncokret, uljana repica i druge (Gagro, 1997).

Žetva ječma vrši se u pravilu prije žetve pšenice zbog ranijeg dozrijevanja ječma. Gubitci u žetvi najčešći su zbog polijeganja, čime se smanjuje se prirod i kakvoća, pogotovo pivarskog ječma kod kojeg dolazi do povećanja udjela bjelančevina (Gagro, 1997). Žetva ječma se u pravilu odvija krajem svibnja i početkom lipnja.

Svi navedeni agroekološku uvjeti ječma ukazuju na njegove potrebe i time omogućuje donosiocu odluka lakše upravljanje poljoprivrednim dobrom. Na temelju agroekoloških uvjeta mogu se određivati težinski koeficijenti kriterijima koji su određeni unutar višekriterijske analize (MCDA) s obzirom na to da nemaju svi usjevi jednake zahtjeve.

4.1.3. Ječam u Hrvatskoj

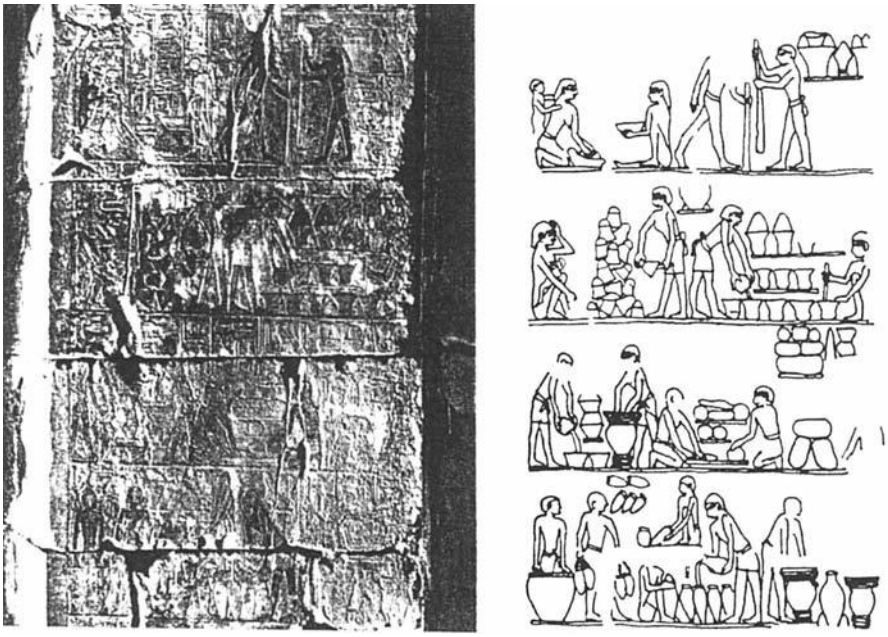
U Hrvatskoj je ječam iznimno zahvalna poljoprivredna kultura, a isplativost njegova uzgoja sve je prepoznatljivija u pivarskoj industriji u kojoj se prvenstveno koristi onaj dvoredni (Martinčić i Kolak, 1993). Višeredni ječam je bogatiji bjelančevinama i daje veći prirod, stoga se upotrebljava u prehrani domaćih životinja, dok dvoredni ječam ima krupnije

zrno s više ugljikohidrata te je stoga pogodniji za pivarsku industriju (Gagro, 1997). Ječam je podložan abiotskim i biotskim stresovima koji su uzrokovani bolestima biljke, visokim amplitudama temperature i količinom oborina, kiselim tlima itd. (Lalić i dr., 2007) te je stoga potrebno pažljivo odabrati kvalitetno tlo za njegov uzgoj. Poljoprivredni institut u Osijeku provodio je istraživanje od 1970. do 2002. godine o urodu zrna ječma. Rezultati istraživanja su pokazali prosječan urod zrna oko 3 t/ha, iako je u pojedinim razdobljima prosječan urod kod ozimog ječma bio 7,40 t/ha, a kod jarog ječma 5,98 t/ha (Lalić i dr., 2007). U novije vrijeme proizvodnja ječma se stabilizirala zbog sve većeg interesa pivarske industrije i sve većeg prinosa ječma po jedinici površine, no također se povećala i ukupna površina na kojoj se uzgaja ječam (Martinčić i Kolak, 1993). Sredinom 80-tih godina 20. st. ječam se u Hrvatskoj uzgajao na površini oko 60 000 hektara s prosječnim prinosom zrna 3 t/ha (Martinčić i Kolak, 1993), a 2017. godine na površini oko 54 000 hektara s prosječnim prinosom zrna 4,6 t/ha (URL 4). U usporedbi s Europom, proizvodnja ječma u Hrvatskoj je u europskom prosjeku, iako države poput Francuske, Ukrajine, Njemačke i Poljske daleko prednjače (Martinčić i Kolak, 1993). U Hrvatskoj postoji težnja da se formira određeno „Gospodarsko udruženje proizvođača piva, slada i ječma“ u svrhu povezivanja i poticanja znanosti i proizvodnje poljoprivrednih kultura, prodaje visokokvalitetnog piva i drugo (Martinčić i Kolak, 1993). Na području Osječko-baranjske županije izrađen je model relativne pogodnosti poljoprivrednog zemljišta koji ukazuje da se najviše površina odlikuje kao klasa S2 FAO-ve klasifikacije pogodnosti zemljišta (Vukadinović i dr., 2014). Na temelju tog modela izrađene su očekivane visine prinosa za ratarske kulture koje za ječam iznose u prosjeku 5,41 t/ha (Vukadinović i dr., 2014).

4.1.4. Pivo i pivarski ječam

Još od prapovijesti, razne vrste alkohola su se koristile u svakodnevnom životu, a na to upućuju arheološki nalazi koji datiraju još iz neolitika. Ljudi su vjerovali kako alkoholni napitci imaju poseban utjecaj na čovjeka te da ih alkohol približava bogovima i produžuje život, stoga se često koristio u religijskim obredima što mu je pridavalo veliko značenje (Rosso, 2013). Također, bitno je naglasiti kako su pivo i kruh bili osnovna hrana ljudima, a ponekad i naknada kojom su bili plaćeni radnici u Mezopotamiji, Siriji, antičkom Egiptu i Rimskom carstvu (Hornsey, 2003). To dokazuju nalazi iz grobnica iz tog razdoblja u kojima su se nalazile posude u kojima su čuvani alkoholni napici, pronađene peći, posude zapremine

300 – 500 litara i sobe koje su služile za proizvodnju i skladištenje piva (Rosso, 2013; Hornsey, 2003)(Sl. 1).



Slika 2. Nalazi iz egipatskih piramida o pripravi piva (preuzeto od Hornsey, 2003)

Posebno je zanimljiv nalaz krhotine staklene bočice koja potječe iz razdoblja kasnog Uruka i koja se koristila za skladištenje piva. S unutarnje je strane bila prevučena materijalom na kojem se zadržavao talog piva (Hornsey, 2003). Kroz srednji vijek, pivo i vino su bila najučestalija pića koja su se konzumirala, a zbog toga što alkohol uzrokuje „opuštajuće osjećaje“ i „smanjuje bol“ često se koristio i u medicini. Za razliku od vina, pivo je bogatije hranjivim tvarima koja su potrebna čovjeku za svakodnevni život, stoga je praksa pijenja piva bila zastupljena kod svih starosnih skupina pa čak i kod djece (Rosso, 2013). Pivo je kroz povijest igralo ogromnu ulogu u razvoju socijalnih odnosa u društvu, pile su ga sve društvene klase pa čak i žene, stoga možemo reći kako je pivo povezivalo ljude i unapređivalo njihove društvene odnose, još od doba Egipta i Mezopotamije (Hornsey, 2003). Što se tiče Hrvatske, grad Osijek je poznat po svojoj tradiciji proizvodnje piva. Prvi zapisi o proizvodnji piva potječu iz 1697. godine što ga čini jednim od najstarijih europskih gradova u kojemu se proizvodilo pivo (URL 5). Daljnjim razvojem društva i geografskim otkrićima, kultura pijenja piva se proširila na čitav svijet i može se reći da se zadržala i do danas.

Iz svega navedenog, jasno je kako je proizvodnja piva bila od iznimne važnosti kroz prošlost, a tako i svi drugi poslovi koji su bili vezani uz proizvodnju piva: od uzgoja ječma i drugih poljoprivrednih kultura pa sve do njegove distribucije i konzumacije (Hornsey, 2003).

Pretpostavlja se kako je ječam „evoluirao“ iz hrane u piće u Mezopotamiji, gdje su ječam natapali u vodi i onda ga sušili na suncu 3 tjedna kako bi dobili slad koji se kasnije mljevenjem i vrenjem pretvarao u pivo, iako je sličan način pripreme piva pronađen i u Egiptu (Hornsey, 2003). Iz toga se može zaključiti kako je uzgoj ječma prednjačio nad uzgojem drugih poljoprivrednih kultura.

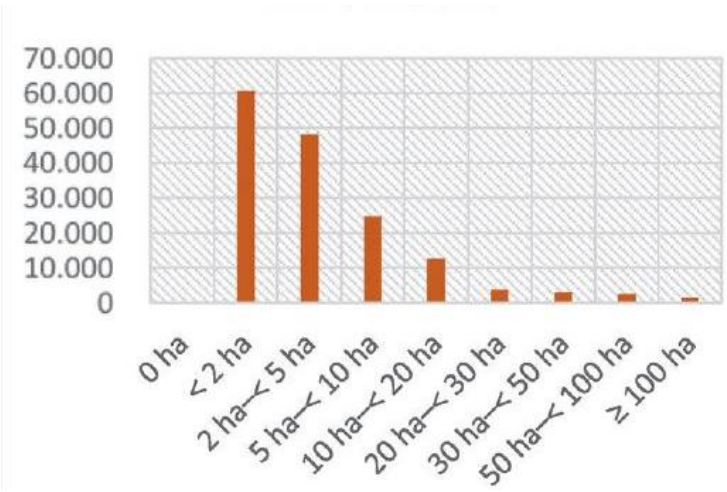
Kao što je već navedeno, dvoredni ozimi ječam se u pravilu koristi za proizvodnju slada i piva. Provedeno istraživanje Poljoprivrednog instituta Osijek (Lalić i dr., 2007) donosi zaključak da su u usporedbi kvalitete slada ozimog i jarog ječma, sorte jarog ječma imale nepovoljniji, viši sadržaj bjelančevina u odnosu na sorte ozimog ječma, ali bolje pokazatelje razgrađenosti slada i niži viskozitet. Uzgoj ječma za pivarsku industriju vrlo je zahtjevan i osjetljiv zbog toga što je potrebno proizvesti vrhunsku kvalitetu kako bi se zadovoljile potrebe pivarske industrije. Kako bi se mogao koristiti u pivarskoj industriji, plod ječma ne smije sadržavati više od 12 % bjelančevina, a ako se koristi višeredni ječam s većim udjelom bjelančevina, tada bjelančevine moraju biti visokomolekularne s većim udjelom sumpora (Gagro, 1997). Tu se nameće problem kvalitete uroda ječma zbog toga što je ječam podložan biotskim i abiotskim stresovima i drugim, kao što je već navedeno. Svi navedeni razlozi utječu na intenzitet i trajanje nalijevanja zrna te može doći do prisilne zriobe (Lalić i dr., 2007). Što se tiče Republike Hrvatske, ozimi ječam ostvaruje više i sigurnije urode u odnosu na jari ječam zbog toga što bolje iskorištava jesensku i zimsku vlagu te je otporniji na sušu jer dozrijeva prije ljeta (Lalić i dr., 2007). Potrebno je oplemenjivati ječam i provoditi znanstveno-istraživačke radove kako bi se stvorila što kvalitetnija sorta pivarskog ječma koji bi imao visoke urode zrna i visoku kvalitetu (Lalić i dr., 2007) jer u Republici Hrvatskoj postoji duga tradicija proizvodnje piva i sve veća tendencija otvaranja malih pivovara.

4.2. POLJOPRIVREDA U HRVATSKOJ

Poljoprivreda je najstarija gospodarska grana pa je tako bila i najvažnija gospodarska grana u Republici Hrvatskoj sve do 20. st. Sredinom 20. st. dolazi do jačeg razvoja industrije te poljoprivreda time pada u drugi plan, no i dalje ostaje neizostavni dio hrvatskog gospodarstva. Iako danas poljoprivreda čini manji udio u ukupnom BDP-u (oko 12 %), veći dio toga spada u agroindustrijsku djelatnost (Magaš, 2013). Takav mali udio dohotka u ukupnom BDP-u treba sagledati kritički, a razlog tomu je što je od sredine 20. st. došlo do

brzog razvoja ostalih djelatnosti poput turizma i industrije, a ne zato što je došlo do smanjenja obujma ili vrijednosti poljoprivredne djelatnosti (Magaš, 2013).

Poljoprivrednim se zemljištem smatra svaka površina (oranice, travnjaci, vrtovi, voćnjaci, livade, pašnjaci, vinogradi i dr) koja se koristi ili ne koristi za poljoprivrednu proizvodnju (NN, 1994). Što se tiče ukupne površine korištene za poljoprivrednu proizvodnju, prema podacima Državnog zavoda za statistiku, u Republici Hrvatskoj se koristi 1,5 milijuna hektara zemljišta u poljoprivredi, od čega oko 53 000 ha spada na uzgoj ječma (DZS, 2018). Udio poljoprivrednih površina je bio u konstantnom rastu do Drugog svjetskog rata, a nakon toga dolazi do postupnog smanjivanja uzrokovanog revitalizacijom šuma, prenamjenom zemljišta i drugo (Magaš, 2013). Prosječna veličina poljoprivrednog zemljišta iznosi oko 5,6 ha (Odak i dr., 2017) što znači da su zemljišta uglavnom usitnjena, iako to ne znači smanjenu poljoprivrednu proizvodnju (Magaš, 2013). Fragmentirana zemljišta predstavljaju veliki problem u održivom gospodarenju zemljištem, a to bi se moglo riješiti okrupnjivanjem zemljište koje omogućuje smanjenje troškova te lakše upravljanje (Odak i dr., 2017).



Slika 3. Poljoprivredna gospodarstva u Hrvatskoj prema veličini zemljišta (preuzeto od Odak i dr., 2017)

S obzirom na to da su se u drugoj polovici 20. st. proizvodili viškovi hrane i poljoprivrednih proizvoda, danas se u poljoprivredi javljaju veliki problemi. Ti problemi nisu isključivo vezani uz ratna zbivanja od 1991. do 1995. godine, već se tu nameće problem prenamjene poljoprivrednog zemljišta u građevinsko, manjak radne snage u primarnom sektoru i usitnjene poljoprivredne površine (Magaš, 2013). Bez obzira na probleme koji se nameću, poljoprivreda u Hrvatskoj daje dobre rezultate. Vrlo povoljna prirodno-geografska osnova, povoljna pedološka i klimatska situacija, visoki prinosi u biljnoj i stočarskoj

proizvodnji, samo su neki od čimbenika koji čine istočni, nizinski dio Hrvatske najvažnijom poljoprivrednom regijom. Na tom prostoru prevladava uzgoj žitarica (kukuruz, pšenica, ječam, zob) i industrijskog bilja (uljane repice, suncokreta, šećerne repe, duhana) i drugo (Magaš, 2013). Također, bitne su i poljoprivredne grane poput stočarstva (svinjogojstvo i govedarstvo) i voćarstva. U brežuljkastim dijelovima istočne Hrvatske (prostori Erduta, Iloka, Kutjeva, Požege i drugo) vrlo je razvijeno vinogradarstvo. Od žitarica, glavna kultura je kukuruz koji se uzgaja na preko 300 000 hektara površine s prinosima od oko 7 t/ha. Kukuruz slijedi pšenica, koja se uzgaja na oko 200 000 hektara te ječam na oko 50 000 hektara površine (Magaš, 2013).

4.3. PODRUČJE ISTRAŽIVANJA

Područje istraživanja ovog diplomskog rada je Osječko-baranjska županija, površine 4 155 km^2 i ukupnog broja stanovnika od 283 035 (URL 4) (Sl. 4). Proučavaju se poljoprivredna zemljišta, osobito ona na kojima se uzgaja ječam. Osječko-baranjska županija je smještena na dodiru Drave i Dunava, prostoru Vučičko-karašičke Podravine, Baranje, Donjodravsko-dunavske ravnice i krndijskog osojnog pobrđa (Magaš, 2013) te sa svojom ugodnom klimom i plodnim tlo čini gotovo pa idealno mjesto za poljoprivrednu djelatnost. Taj prostor karakteriziraju izrazite praporne zaravni i praporne terase te riječna aluvijalna tla bogata humusom na kojima su se razvili degradirani oblici plodne crnice (Magaš, 2013). Zapadni dio županije je pošumljeniji, ispresijecan brojnim vodotocima, stoga se na tom prostoru razvija poljodjelstvo i ribnjačarstvo (Magaš, 2013). Prostor Baranje dugo je vremena gravitirao Mađarskoj, no nakon oslobođenja od Osmanlija dolazi do velikog naseljavanja Hrvata, Mađara i Nijemaca što je potaknulo veliku valorizaciju tog kraja u agrostočarskom smislu (Magaš, 2013). Prostor središnjeg dijela županije, uz tok rijeke Vuke bio je zamočvaren do 19. st. Nakon melioracijskih zahvata i uspostave tropoljnog sustava, prostor oko Vuke postaje jedan od najsuvremenijih i najvrijednijih agrarnih krajeva Hrvatske (Magaš, 2013). Osijek ima značajnu ulogu gospodarskog i prometnog središta istočne Hrvatske. Rana pojava industrijalizacije, plodno zemljište, povoljni prirodno-geografski i društveno-geografski uvjeti i izgradnja nove autoceste neki su od čimbenika koji su značajnije potaknuli razvoj tog kraja (Magaš, 2013).

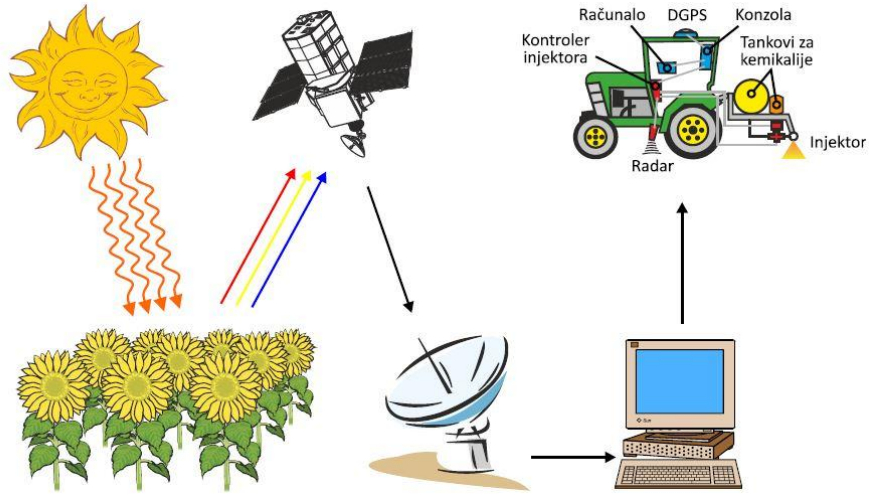


Slika 4. Prostorni smještaj Osječko-baranjske županije

4.4. GEOPROSTORNE TEHNOLOGIJE U POLJOPRIVREDI

S napretkom tehnologije dolazi do integriranja GIS-a i daljinskih istraživanja u različite sfere ljudskog života (razvoj pametnih gradova, zaštita okoliša, upravljanje prostorom itd.). GIS kao alat geoprostornih tehnologija omogućava obradu, upravljanje, organizaciju, analizu i interpretaciju prostornih podataka (Grubišić, 2014). U vezi s time, posljednjih godina GIS tehnike igra značajnu ulogu u razvoju poljoprivredne djelatnosti, posebice od 1990-tih godina kada dolazi do stvaranja novih koncepata i pristupa u planiranju i upravljanju poljoprivredom (Marić i dr., 2019). Poljoprivreda bi danas bila gotovo pa nezamisliva bez upotrebe geoprostornih tehnologija jer one omogućavaju izradu brojnih modela i kartografskih prikaza koji, uz savjete stručnjaka, pomažu pri donošenju odluka o upravljanju poljoprivrednom površinom (Manić i dr., 2016). Razlozi toj integraciji su smanjenje troškova proizvodnje, lakše upravljanje poljoprivrednim sustavima, veća produktivnost, veća kvaliteta poljoprivrednih proizvoda i drugi (Manić i dr., 2016). S obzirom na to da je poljoprivreda jedna od najbitnijih grana hrvatskog gospodarstva, važno je da se maksimizira poljoprivredna produktivnost i kvaliteta završnih proizvoda. Stoga se nameće važnost upotrebe geoprostornih tehnologija za razvoj sustava za monitoring i upravljanje u poljoprivredi. Jedan od takvih koncepata je *precizna poljoprivreda* koja se temelji na uštedi

vremena, materijala, novca te povećanju produktivnosti i kvalitete poljoprivrednih kultura (Rapčan i dr., 2018). Glavna komponenta u takvom pristupu je korištenje informacijskih tehnologija, različitih vrsta geotehnologija poput GPS navođenja, multispektralnih senzora, automatiziranog upravljanja poljoprivrednom mehanizacijom itd. (Marić i dr., 2019). GIS omogućuje optimizaciju takvog sustava u kojem postoje jasno definirani *inputi* i *outputi* te kao takav sustav pomaže poljoprivredniku u donošenju odluka i monitoringu u realnom vremenu (Rapčan i dr., 2018; Grubišić, 2014). Poljoprivredniku se omogućuje smanjenje upotrebe gnojiva, smanjeni utjecaj na okoliš, povećanje prinosa, veća kontrola uzgoja i drugo (Jurišić i dr., 2015). Na makro razini, GIS se može koristiti kao sustav za upravljanje i planiranje poljoprivrednim površinama većeg prostora jer se mogu modelirati ne samo prirodno-geografski, već i društveno-geografski čimbenici (Manić i dr., 2016) koji mogu izravno utjecati na poljoprivrednu proizvodnju (npr. broj radne snage, infrastruktura, udaljenost od naselja i drugi).



Slika 5. Daljinska istraživanja u poljoprivredi (preuzeto od Vukadinović i Vukadinović, 2018)

Nove tehnologije u poljoprivredi omogućavaju kreiranje baza podataka čiji se podaci mogu jednostavno pretraživati i koristiti u svrhu izrade digitalnih karata i modela (Manić i dr., 2016). Ti podaci mogu biti prikupljeni posebnom mehanizacijom koja se postavlja na traktore ili bespilotne letjelice (Sl. 5). Upotrebom sofisticiranih senzora i računala, upravljačkih i regulacijskih sklopki te GPS-a, moguće je kontrolirati količinu i način prskanja, sijanja, prihranjivanja, planiranja pravca kretanja i drugih radnji koje se obavljaju tom mehanizacijom (Jurišić i dr., 2015; Manić i dr., 2016). Područja koja se trebaju zaštititi od korova ili nametnika trebaju različite količine sredstva za tretiranje, stoga primjena GIS-a omogućuje

prethodno određivanje količina i mjesta tretiranja te izradu plana kako bi se radnje zaštite biljaka pravilno i automatizirano izvršile (Jurišić i dr., 2015). Upravljanje mehanizacijom odvija se putem GPS-a koji točno određuje poziciju mehanizacije i plan puta, a sve u svrhu smanjenja broja prohoda i potrošnje goriva (Rapčan i dr., 2018). Također, daljinska istraživanja su neizostavna tehnika praćenja i planiranja u poljoprivredi. S obzirom na to da cijene određenih tehnologija postaju sve jeftinije, dolazi do učestalijeg korištenja bespilotnih letjelica u poljoprivredi koje dolaze zajedno s multispektralnim, laserskim, infracrvenim senzorima te s računalnim programima koji omogućavaju prikupljanje i analizu podataka, planiranje leta letjelice i drugo (Vukadinović i Vukadinović, 2018). Kako se u poljoprivredi koriste velike površine za uzgoj hrane, jasno je da su bespilotne letjelice idealan i efikasan alat za praćenje stanja usjeva, zaštite od bolesti, utvrđivanje potrebe za prihranom, navodnjavanjem i drugim agrotehničkim mjerama (Vukadinović i Vukadinović, 2018) poput utvrđivanja rasta vegetacije, zdravlja vegetacije (NDVI), sastava i kvalitete tla (SAVI), količine oborina, stupnja erodiranosti, izradu digitalnih karata i modela te drugih čimbenika (Zhang i Kovacs, 2012; Pierce i Clay, 2007). Pri upotrebi tehnologija daljinskih istraživanja treba obratiti pozornost na prostornu rezoluciju. Ako se radi o prikupljanju informacija na makro razini, tada se mogu koristiti satelitski sustavi kao što su Landsat TM, ASTER, SPOT 5 i drugi, no ako se radi o istraživanju na mezo ili mikro razini (metarske, centimetarske ili milimetarske prostorne rezolucije), tada se koriste bespilotne letjelice ili baloni (Zhang i Kovacs, 2012) (Sl. 6). Bez obzira na tehnologiju koja se koristi, dobivene informacije pomažu u donošenju odluka, praćenju i planiranju, izradi modela i kartografskih prikaza, zaštiti bilja itd. Spoj aerofotogrametrije, satelitskih snimaka i GIS-a značajno je pridonio razvoju poljoprivredne djelatnosti, mogućnost zoniranja i generiranja određenih podataka poljoprivrednicima daje dodatni poticaj i sigurnost (Pierce i Clay, 2007).



Slika 6. Primjer dronova korištenih u poljoprivredi (preuzeto od Zhang i Kovacs, 2012)

4.5. KVANTITATIVNE ANALIZE

Kvantitativne analize su sve one analize koje se u istraživanjima oslanjaju na teoriju vjerojatnosti i uključuju statističke podatke te se rezultati takvih analiza mogu koristiti u izradi modela (Creswell, 2013). Metode kvantitativnih istraživanja su se razvijale kroz 19. i 20. stoljeće, no značajni je razvoj pratio razvoje računalnih tehnologija koje su omogućile izradu kompleksnih analiza i obradu statističkih podataka (Creswell, 2013). One istraživaču omogućuju usporedbu dviju ili više skupina podataka koji se koriste u analizama te uključuju identifikaciju kolektivne snage višestrukih varijabli (Creswell, 2013). Na primjer, determinizam sugerira da je ispitivanje odnosa između varijabli ključno za odgovaranje na pitanja i hipoteze putem istraživanja i eksperimenata (Creswell, 2013).

4.5.1. Višekriterijske GIS analize

Jedna od metoda kvantitativnog istraživanja su višekriterijske analize (MCDM - *Multi-Criteria Desicion Making*). Višekriterijska GIS analiza predstavlja skup metoda i alata koji omogućuju transformiranje i kombinaciju geografskih podataka i vrednovanih kriterija u svrhu generiranja informacija za odlučivanje (Malczewski i Rinner, 2015). Višekriterijske analize pomažu ljudima pri donošenju odluka u problemima koji imaju već broj varijabli, a najčešće se koriste u programiranju gdje postoji više matematičkih funkcija (Malczewski i Rinner, 2015; Triantaphyllou, 2000). Njihova karakteristika je u tome da se određeni problem podijeli na više dijelova te se izvedu alternative (odluke), pri čemu različite metode višekriterijskih analiza pomažu donositelju odluka u odlučivanju o važnosti kriterija (Triantaphyllou, 2000). Također, GIS omogućuje pohranu, analizu i vizualizaciju geoprostornih podataka koji analitičarima i donositeljima odluka pomažu u odlučivanju o prostornim odnosima na sofisticiraniji i smisleniji način (Malczewski i Rinner, 2015). S obzirom na to da postoji više kriterija, oni se strukturiraju u hijerarhiju prema njihovim težinskim koeficijentima, zbog toga što nemaju svi kriteriji istu važnost (Triantaphyllou, 2000). Bez obzira na korištenu metodu, u višekriterijskim GIS analizama postoji 5 ključnih koraka:

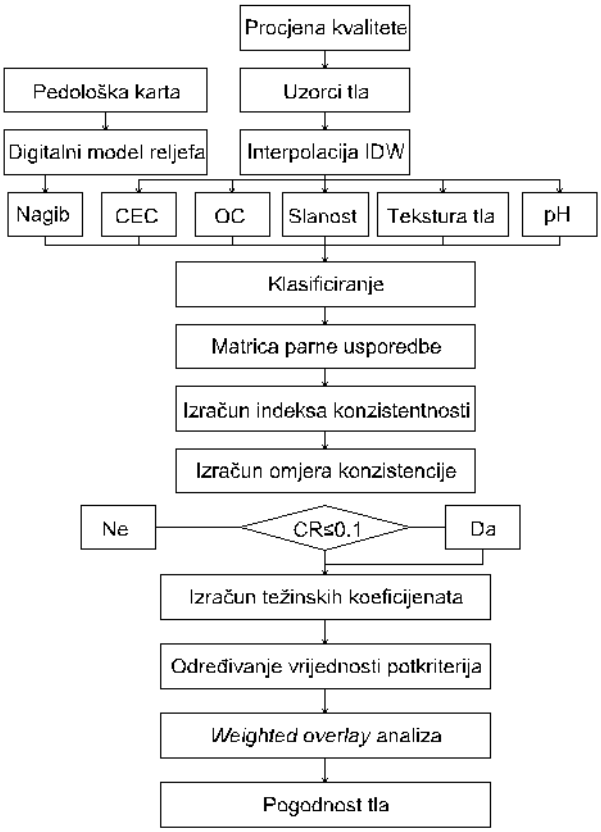
1. Određivanje kriterija i alternativa

2. Prikupljanje prostornih podataka

3. Određivanje težinskih koeficijenata

4. Analiziranje podataka GIS tehnikama

5. Provjera rezultata (Malczewski, 2004).



Slika 8. Primjer višekriterijske GIS analize pogodnosti zemljišta (preuzeto od Ennaji i dr., 2018)

Neke od višekriterijskih metoda su: model ponderiranog iznosa (WSM – *Weighted Sum Model*), model ponderiranog proizvoda (WPM – *Weighted Product Model*), proces analitičke hijerarhije (AHP – *Analytic Hierarchy Process*), „prerađeni" AHP, stvarnost eliminacije i izbora (ELECTRE – *Elimination and Choice Translating Reality*), tehnika za određivanje redoslijeda sličnosti s idealnim rješenjem (TOPSIS – *Technique for Order Preference by Similarity to Ideal Solution*) i druge metode (Triantaphyllou, 2000). Sve ove navedene metode koriste numeričke tehnike koje pomažu donositelju odluka da odabere određenu alternativu što se postiže na temelju utjecaja alternativa na određene kriterije, a time i na ukupnu odluku (Triantaphyllou, 2000). Stoga sve ove metode imaju sve veću implementaciju u računalnim tehnologijama zbog toga što na vrlo jednostavan način omogućuju izradu i vizualizaciju prostornih podataka. Zahvaljujući spoju kvantitativnih

metoda i GIS-a omogućeno je generirati velike količine podataka korištenjem geostatističkih alata i tehnika (Vukadinović i Vukadinović, 2018) (Sl. 8).

4.5.2. Proces analitičke hijerarhije (AHP)

Proces analitičke hijerarhije (AHP) je jedna od najpoznatijih i najkorištenijih metoda u rješavanju problema gdje postoji više raspoloživih mogućnosti (Crnčan i dr., 2016). AHP dijeli kompleksnu višekriterijsku analizu na manje komponente i uređuje ju u hijerarhiju. Te komponente predstavljaju zadane kriterije koji se uspoređuju u odnosu na druge pomoću sheme „parne usporedbe“, a rezultat te usporedbe je skup prioriteta kriterija (Saaty, 2008). Svaka AHP analiza sastoji se od 5 osnovnih koraka:

1. Definiranje problema
2. Strukturiranje elemenata u kriterije i potkriterije
3. Izrada „parne usporedbe” matrice elemenata za sve kriterije
4. Izračunavanje težinskih koeficijenata i omjera konzistentnosti
5. Provjera rezultata (Saaty, 2008).

Nakon što je definiran problem i postavljen cilj istraživanja, trebaju se odabrati kriteriji koji će se uspoređivati. Kako bi se napravila usporedba, potrebna je skala brojeva koja pokazuje koliko je puta važniji ili dominantniji jedan element nad drugim elementom s obzirom na kriterije koji se uspoređuju (Saaty, 2008).

Tablica 2. Temeljna skala apsolutnog broja

Intenzitet važnosti	Definicija	Objašnjenje
1	Jednaka važnost	Dva kriterija jednako pridonose cilju
2	Slabo ili malo važnije	
3	Osrednje važno	Iskustvo i prosudba malo favoriziraju jedan kriterij nad drugim
4	Osrednje plus	
5	Jaka važnost	Iskustvo i prosudba snažno favoriziraju jedan kriterij nad drugim

6	Jaka plus	
7	Vrlo jaka ili demonstrirana važnost	Kriterij je vrlo snažna u odnosu na drugi; dominacija pokazana u praksi
8	Vrlo, vrlo jaka važnost	
9	Ekstremna važnost	Favoriziranje kriterija nad drugim ima najveći mogući red afirmacije
Recipročne vrijednosti	Ako aktivnost I ima dodijeljen neki broj 1-9 nad aktivnosti J, tada aktivnost J ima recipročnu vrijednost u usporedbi s aktivnosti I	Razumna pretpostavka
1,1 – 1,9	Ako su aktivnosti jako bliske važnosti	Razlike su iznimno male, ali i dalje mogu pokazati na relativnu važnost

Izvor: (Saaty, 2008)

Nakon što je izrađena skala intenziteta važnosti, može se pristupiti izradi matrice u kojoj će se svi kriteriji uspoređivati jedan s drugim. Svakom se kriteriju pridaje njegova važnost u odnosu na drugi kriterij. Pridavanje važnosti kriterijima se temelji na iskustvu, obuci ili savjetima stručnjaka (Saaty, 1990). Nakon što je izrađena matrica s pridodanim vrijednostima, izračunava se faktor prioriteta za svaki kriterij. Kako bi se odredio faktor prioriteta, prvo se treba izračunati suma svih pridodanih važnosti za svaki kriterij. Nakon toga, svaku pridodanu važnost treba podijeliti s dobivenom sumom, a prosjek vrijednosti koji se dobije predstavlja faktor prioriteta (Saaty, 1990). Glavna zadaća je provjera omjera konzistencije CR koji mora iznositi manje od 0,1 kako bi se pridodane važnosti koje su odabrane mogle smatrati ispravnima (Saaty, 1990). Kako bi se izračunao CR, prvo se treba izračunati svojstvena vrijednost λ_{max} te indeks konzistentnosti CI (Saaty, 1990). Svojstvena vrijednost jednaka je zbroju umnožaka faktora prioriteta i sume pridodanih važnosti za svaki kriterij:

$$\lambda_{max} = (Fp1 * \sum pv1) + (Fp2 * \sum pv2) + ...(FpN * \sum pvN)$$

Fp1 – faktor prioriteta kriterija 1,

$\sum$pv1 – suma pridodanih važnosti kriterija 1.

Kada se izračuna svojstvena vrijednost, tada se treba izračunati indeks konzistentnosti CI:

$$CI = (\lambda_{max} - n) / (n - 1)$$

λ_{max} – svojstvena vrijednost

n – broj kriterija.

S dobivenim vrijednostima može se izračunati omjer konzistencije CR:

CR = CI / RI

CI – indeks konzistentnosti

RI – indeks slučajne konzistencije.

Indeks slučajne konzistencije ovisi o broju kriterija u izrađenoj matrici te je za svaki broj kriterija različit. Ako je vrijednost omjera konzistencije manji ili jednak 0,1, nedosljednost je prihvatljiva, a ako je veći od 0,1, tada se treba razmotriti revizija subjektivne prosudbe donositelja odluka (Saaty, 1990). Iz ovoga se može zaključiti kako je potreban organizirani način donošenja odluka i prikupljanja informacija koje su važne pri donošenju odluka (Saaty, 2008).

Tablica 3. Indeks slučajne konzistencije

N	1,2	3	4	5	6	7	8	9	10
RI	0,00	0,58	0,90	1,12	1,24	1,32	1,41	1,45	1,49

Izvor: (Setiawan i dr., 2014)

4.5.3. Indeks zdravlja vegetacije

Indeks zdravlja vegetacije (NDVI – *Normalized Difference Vegetation Index*) predstavlja kvantificiranu vrijednost zdravlja vegetacije koja se temelji na razlici između infracrvenog i crvenog kanala satelitskih snimaka (URL 6). Satelitske snimke *Sentinel 2* imaju 12 kanala gdje svaki kanal ima raspon valne duljine zračenja i svoju prostornu rezoluciju (URL 7).

Tablica 1. Sentinel 2 kanali

Sentinel 2A kanali	Valna duljina (nm)	Prostorna rezolucija (m)
Kanal 1 – obalni aerosol	442,7	60
Kanal 2 – plava	492,4	10
Kanal 3 – zelena	559,8	10
Kanal 4 – crvena	664,6	10
Kanal 5 – rubna crvena	704,1	20

Kanal 6 – rubna crvena	740,1	20
Kanal 7 – rubna crvena	782,8	20
Kanal 8 – infracrvena	832,8	10
Kanal 9 – vodena para	945,1	60
Kanal 10 – SWRI - cirus	1373,5	60
Kanal 11 - SWRI	1613,7	20
Kanal 12 - SWRI	2202,4	20

Izvor: (URL 7)

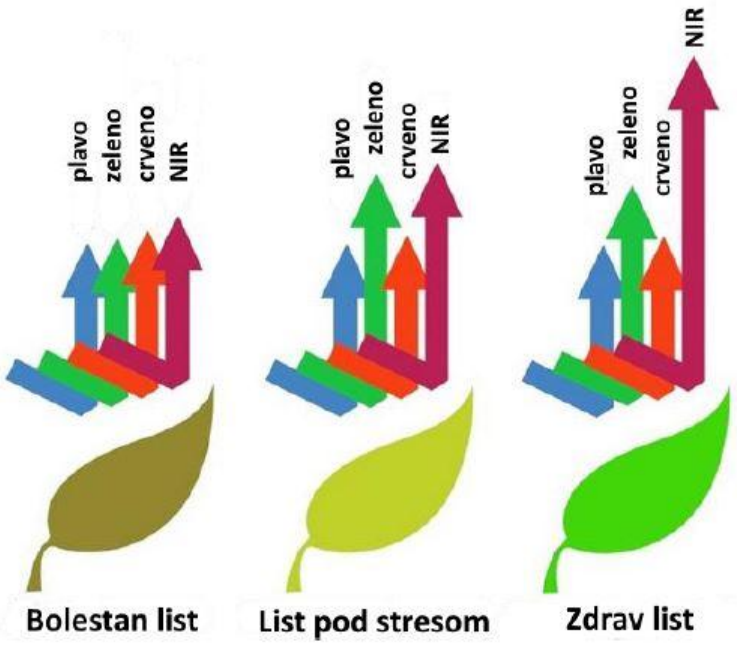
S obzirom na to da je vegetaciji potrebna sunčeva svjetlost kako bi vršila proces fotosinteze, zdrava vegetacija upija vidljivi dio spektra (valne duljine 400 – 700 nm), a reflektira infracrvene i zelene zrake (URL 6). Biljke su razvile mehanizam odbijanja infracrvenog spektra zbog toga što je energija fotona u tom spektru (preko 700 nm) premala za sintezu organskih molekula (URL 14). To znači da zdrava vegetacija, gledana kroz infracrveni spektar izgleda bijele boje jer bijela boja predstavlja refleksiju svjetlosti (Sl. 7). Suprotno tomu, oblaci, snijeg i vodene površine, gledani kroz infracrveni spektar poprimaju tamne nijanse crvene boje (URL 14), čime se postiže jasan kontrast između zdrave i nezdrave vegetacije. Prema tomu, formula za izračun indeksa zdravlja vegetacije glasi:

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)}$$

NIR – približno infracrveni kanal

Red – crveni kanal.

Vrijednosti izlaznog rezultata kreću se od -1 do 1 gdje negativne vrijednosti predstavljaju vodu, snijeg, oblake ili prostore bez vegetacije, a pozitivne vrijednosti predstavljaju zdravu vegetaciju. Stoga vrijednosti koje su bliže maksimalnoj vrijednosti NDVI indeksa predstavljaju zdraviju vegetaciju, a pozitivne vrijednosti bliže 0 predstavljaju slabije razvijenu ili bolesnu vegetaciju. Dobiveni podaci imaju široku primjenu, a najviše se koriste u poljoprivredi i upravljanju prostorom (Pierce i Clay, 2007; URL 6).



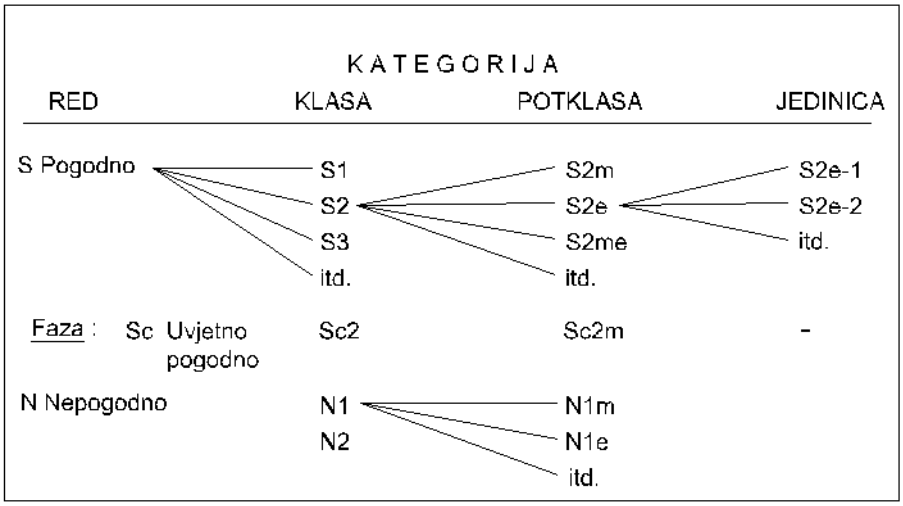
Slika 7. Princip spektralne analize zdravlja vegetacije (preuzeto od Vukadinović i Vukadinović, 2018)

4.6. FAO KLASE POGODNOSTI ZEMLJIŠTA

Pogodnost nekog zemljišta označava stupanj njegove prikladnosti za korištenje u određenu svrhu (URL 15). Postupak klasifikacije zemljišta prikladan je za ocjenjivanje i grupiranje određenih zemljišta prema njihovoj prikladnosti za definiranu uporabu. Te klase izrađuju se s obzirom na način korištenja zemljišta za određeno područje. Na primjer, u određenom području za koje se smatra da je moguća poljoprivredna, stočarska ili šumarska namjena postoji zasebna klasifikacija (FAO, 1976). Unutar klasifikacije postoje dva reda, S i N. S-red predstavlja red pogodnih klasa koje označavaju zemljišta čija trajna uporaba dovodi do uroda koji opravdava *input* bez neprihvatljivog rizika od oštećenja zemljišnih resursa (URL 15) (Sl. 9). Red N predstavlja klase zemljišta koja nemaju dovoljnu kvalitetu kako bi omogućile održivu uporabu nekog zemljišta (URL 15). Zemljišta se mogu klasificirati kao nepogodna (N-red) ako uporaba nekog zemljišta nije tehnički izvediva (npr. navodnjavanje strmih stjenovitih zemljišta) ili ako će prouzrokovati ozbiljniju degradaciju okoliša (URL 15).

Redovi S i N se dalje granaju na klase (Tablica 6). Klasa S1 (vrlo pogodno) predstavlja zemljišta koja nemaju značajna ograničenja za trajnu uporabu ili imaju samo manja ograničenja koja neće u većoj mjeri smanjiti produktivnost i neće povećati *input* za

neku namjenu iznad prihvatljive razine (URL 15). Klasa S2 (umjereno pogodno) predstavlja zemljišta čija su ograničenja umjerena za trajnu uporabu, ograničenja koja će smanjiti produktivnost i povećati potrebe *inputa* u tolikoj mjeri da će biti dovoljno atraktivna, ali znatno inferiornija u odnosu na klasu S1 (URL 15). Klasa S3 (marginalno pogodno) predstavlja zemljišta s ograničenjima koja su u cjelini ozbiljna za trajnu uporabu i time smanjuju produktivnost i povećavaju inpute za uporabu te je tako korist zemljišta neznatno opravdana (URL 15). U ovoj klasifikaciji, *inputi* i korist trebaju se iskazati u mjerljivim crtama. Različite varijable u različitim okolnostima mogu jasnije izraziti stupanj pogodnosti neke klase, npr. raspon očekivanog neto prinosa po jedinici površine i dr. Taj stupanj pogodnosti klase određen je odnosom *inputa* i koristi namjene nekog zemljišta. Koristi se sastoje od dobara kao što su usjevi, stočni proizvodi, drvo, usluge, rekreacijski sadržaji itd. *Inputi* potrebni za postizanjem te koristi su kapital, ulaganja, radna snaga, gnojivo itd. (URL 15). Stoga se neko zemljište može svrstati u klasu S1 (visoko pogodno) jer su vrijednosti proizvedenog znatno veće nego troškovi uzgoja.



Slika 9. FAO klasifikacija pogodnosti zemljišta (URL 15)

Klasa N1 (trenutno nepogodno) predstavlja zemljište koje ima ograničenja koja mogu biti vremenski premostiva, ali koja se trenutnom tehnologijom i neprihvatljivim cijenama ne mogu otkloniti, ograničenja koja onemogućavaju uspješnu održivu uporabu nekog zemljišta (URL 15). Klasa N2 (trajno nepogodna) predstavlja zemljište s ograničenjem u tolikoj mjeri da onemogućavaju bilo kakvu mogućnost korištenja zemljišta na održivi način, najčešće fizička i trajna ograničenja (URL 15).

Nadalje, u FAO klasifikaciji klase se mogu dalje dijeliti na podklase, a podklase na jedinice, no za potrebe ovog rada to nije potrebno.

5. METODOLOGIJA RADA

Upotreba računalnih tehnika i tehnologija u velikoj mjeri doprinosi izradi višekriterijskih GIS analiza (Malczewski i Rinner, 2015). Glavni cilj ovog diplomskog rada je izrada modela vrednovanja poljoprivrednog zemljišta za uzgajanje ječma na prostoru Osječko-baranjske županije. Metode korištene u izradi diplomskog rada su: višekriterijske analize, GIS-metode, daljinska istraživanja, analiza literature itd. Koristi se računalni programi *ArcMap 10.01* i njegove pojedine ekstenzije, zatim *SAGA GIS, Erdas Imagine 2014, Excel 2016*. Metodološki doprinos ovoga rada odnosi se na višekriterijsku GIS analizu kao jednu od suvremenih rješenja u planiranju, vrednovanju i donošenju odluka. Proces primjene višekriterijske GIS analize sastoji se od 5, odnosno 6 osnovnih koraka:

1) definiranje problema/postavljanje cilja

2) određivanje kriterija

3) standardiziranje kriterija

4) određivanje težinskih koeficijenata

5) okupljanje kriterija

6) provjera rezultata.

Prvi korak je prikupljanje literature kako bi se objasnio teorijski okvir diplomskog rada te postavio cilj rada. Cilj rada treba biti SMART (*Specific* - određen; *Measurable* - mjerljiv; *Attainable* - ostvariv; *Relevant* - relevantan; *Time bound* - vremenski ograničen) (URL 16). Nakon detaljnog proučavanja literature, određeni su kriteriji (Tablica 4) koji će se koristiti za izradu modela pogodnosti. Ukupno se koristi 10 kriterija koji su grupirani u 5 skupina: geomorfometrijsku, pedološku, klimatsku, hidrološku i ograničavajuću skupinu (Tablica 4). Sljedeći korak je standardiziranje kriterija na jednaku brojevnu skalu kako bi se kriteriji mogli međusobno uspoređivati. Usporedbom kriterija dolazi se do određivanja njihovih težinskih koeficijenata. Svi kriteriji su različite važnosti, stoga ih je potrebno ocijeniti. Nakon što su težinski koeficijenti određeni, potrebno je okupiti kriterije zajedno s ograničavajućim faktorima kako bi se dobio model pogodnosti. Zadnji korak je provjera rezultata kako bi se ustvrdila točnost izrađenog modela.

5.1. ANALIZA LITERATURE

Znanstveni radovi o analizama pogodnosti zemljišta su pomogli pri sagledavanju teme kroz širu sliku te upućuju na točne informacije o tehnologijama i kriterijima koji su potrebni za izradu ovakvih analiza i modela. S obzirom na to da ova tema predstavlja relativno novu problematiku među znanstvenicima, jasno je kako je obujam radova na ovu temu iz godine u godinu sve veći i kvalitetniji. Za teorijski okvir i metodologiju rada potrebno je prikupiti informacije o području istraživanja, uzgoju ječma, geoprostornim tehnologijama i kvantitativnim analizama.

5.2. PRIKUPLJANJE PODATAKA

U procesu prikupljanja podataka, svi kriteriji su izrađeni u 5-metarskoj prostornoj rezoluciji, a određena projekcija je HTRS96/TM na GRS80 elipsoidu. Digitalni model reljefa (DMR) izrađen metodom ANUDEM (Australian National University Digital Elevation Model) u programu ArcMap na temelju izohipsa i visinskih točaka. Izohipse i visinske točke generirane su procesom poluautomatske vektorizacije pomoću programa *WinTopo* s topografske karte u mjerilu 1:25000 (Šiljeg i dr., 2018). Metoda ANUDEM predstavlja jednu od najkompleksnijih i najboljih metoda izrade hidrološko ispravnih modela reljefa s obzirom na ulazne podatke (Šiljeg i dr., 2018).

Karta pH vrijednosti tla dobivena je ručnom vektorizacijom karte *Predikcija pH-KCl zemljišnih resursa OBŽ interpolacija bayesian krigingom* dostupne na internetskoj stranici (URL 9) (Sl. 14). Karta je prvo georeferencirana kako bi se mogla izvršiti vektorizacija. Vektorizacija je izvršena u 9 klasa kako je klasificirano u izvornom obliku. Tijekom vektorizacije, manji dijelovi karte su generalizirani zbog lošije kvalitete rasterskog predloška po kojemu je karta vektorizirana, a problem su predstavljale vrlo zgusnute klase pH vrijednosti na pojedinim dijelovima.

Pedološka karta Republike Hrvatske dobivena je iz KMZ sloja *Interaktivna pedološka karta RH na podlozi Google Earth* (URL 9). U programu *ArcMap 10.1* naredbom *KML To Layer* (*Conversion tool*) datoteka je pretvorena u poligonski sloj te su sloju pridodani odgovarajući tipovi tla.

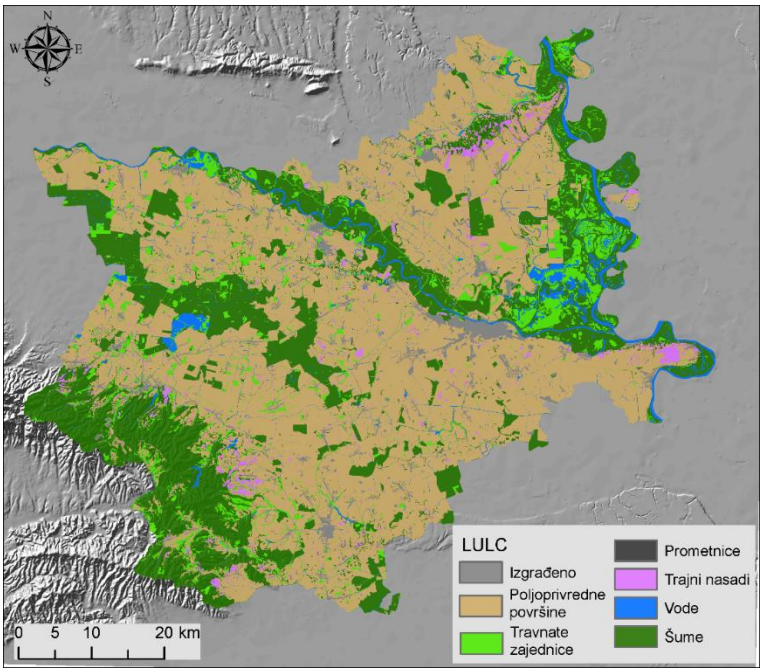
Klimatski podaci su dobiveni s internetske stranice DIVA-GIS na kojoj se mogu besplatno preuzeti podaci o temperaturi i oborinama za pedesetogodišnje razdoblje (1950. –

2000. godine). S obzirom na to da se radi o podacima za cijeli svijet, potrebno je izvesti samo podatke za prostor Osječko-baranjske županije, a to je napravljeno naredbom *Clip* (*Data Management tools*).

Iz podataka OSM-a generirani su podaci o prometnicama gdje su u obzir uzete državne, županijske i lokalne ceste, obilaznice, brze ceste, autoceste i željezničke pruge. Nakon što su izdvojeni podaci o prometnicama, generirana je zona utjecaja od prometnica. Za državne, županijske, lokalne, brze ceste i obilaznicu određena je zona utjecaja od 2 metra sa svake strane od ceste, za autocestu 10 metara. Također, iz dostupnih podataka OSM-a generirana su izgrađena područja (stambene, industrijske, komercijalne zone), trajni nasadi (voćnjaci i vinogradi), zaštićena prirodna područja (PP Kopački rit) i vode (rijeke, jezera, ribnjaci, zamočvarene površine).

5.2.1. Nadzirana klasifikacija

Nadzirana klasifikacija izrađena je u programu *Erdas Imagine 2014* na temelju dvije satelitske snimke potražene za datum 20. travnja 2019. godine. Satelitske snimke dobivene su s besplatne internetske stranice *Earth Explorer* (URL 10). Pri pretraživanju bilo je potrebno odabrati što kvalitetnije satelitske snimke, stoga je kao dodatni kriterij u pretraživanju snimaka zadana naredba za pretraživanje snimaka s manje od 10 % naoblake. S obzirom na to da nije bilo jedinstvene snimke koja obuhvaća cijelu Osječko-baranjsku županije, potražene su dvije susjedne snimke. Nakon toga te dvije snimke je bilo potrebno spojiti u jednu alatom *MosaicPro*. Iz tog generiranog satelitskog snimka bilo je potrebno izvesti samo prostor Osječko-baranjske županije, a to je napravljeno alatom *Create Subset Image*. Zadnji korak je izrada signatura kojima su označeni elementi krajolika te su dobivene klase korištenja krajolika na temelju kojih je izrađena nadzirana klasifikacija. Odabrane klase krajolika su: šume, vode, izgrađeno, poljoprivredne površine i travnjaci. Na temelju nadzirane klasifikacije i dostupnih podataka s OSM-a izrađena je karta korištenja zemljišta (LULC – *Land Use and Land Cover*) (Sl. 10).



Slika 10. Karta korištenja zemljišta

5.3. ODREĐIVANJE KRITERIJA

Kako bi se mogao izraditi model pogodnosti poljoprivrednog zemljišta, potrebno je odrediti kriterije koji će se vrednovati i ograničenja koja omogućuju ili onemogućuju neku pojavu. Kriteriji čine kvantificirane vrijednosti koje pozitivno ili negativno utječu na pogodnost neke pojave, u ovom smislu na model pogodnosti poljoprivrednog zemljišta za uzgoj ječma. Svi kriteriji ovoga rada podijeljeni su u pet skupina: geomorfometrijski, pedološki, klimatski, hidrološki i ograničavajući. Kriteriji su izabrani na osnovi proučene literature te njihovoj dostupnosti i mogućnostima obrade u računalnom programu ArcMap.

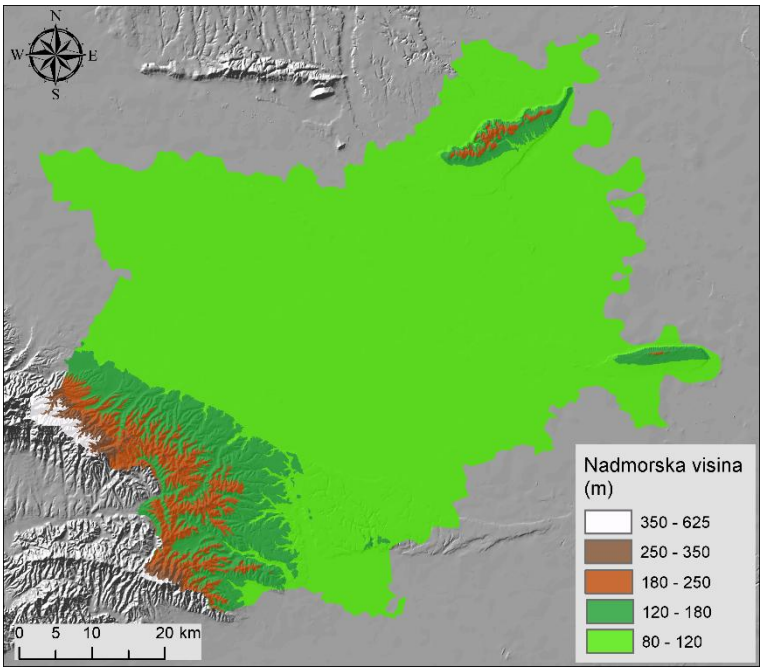
Tablica 4. Kriteriji za izradu modela

	Kriteriji	Izvor	Mjerna jedinica	Autor
Geomorfometrijski	Nadmorska visina	DMR	m	Akinci i dr.(2013), Feizizadeh & Blaschke (2013), Vukadinović i dr.(2014), Mustafa i dr.(2011), Zhang i dr.(2015), Yohannes & Soromessa (2018)
	Nagib	DMR	%	Akinci i dr.(2013), Feizizadeh & Blaschke (2013), Vukadinović i dr.(2014), Zhang i dr.(2015), Yohannes & Soromessa (2018), Ennaji i dr.(2018), Sarkar i dr.(2014), Ahamed i dr.(2000)
	Ekspozicija	DMR	Strana svijeta	Akinci i dr.(2013), Feizizadeh & Blaschke (2013), Vukadinović i dr.(2014), Yohannes & Soromessa (2018)

Pedološki	Kiselost tla	PK 100	pH	Feizizadeh & Blaschke (2013), Vukadinović i dr.(2014), Kazemi & Akinci (2018), Zhang i dr.(2015), Yohannes & Soromessa (2018), Ennaji i dr.(2018), Sarkar i dr.(2014), Ahamed i dr.(2000)
	Tip tla	PK 100	klasa	Akinci i dr.(2013), Vukadinović i dr.(2014), Zhang i dr.(2015)
	Tekstura tla	PK 100	klasa	Vukadinović i dr.(2014), Mustafa i dr.(2011), Kazemi & Akinci (2018), Yohannes & Soromessa (2018), Ennaji i dr.(2018), Sarkar i dr.(2014), Ahamed i dr.(2000)
Klimatski	Temperatura	DIVA-GIS	°C	Feizizadeh & Blaschke (2013), Vukadinović i dr.(2014), Kazemi & Akinci (2018), Zhang i dr.(2015), Yohannes & Soromessa (2018), Sarkar i dr.(2014)
	Oborine	DIVA-GIS	mm	Feizizadeh & Blaschke (2013), Vukadinović i dr.(2014), Kazemi & Akinci (2018), Zhang i dr.(2015), Yohannes & Soromessa (2018), Sarkar i dr.(2014)
Hidrološki	Ocjeditost	DMR	klasa	Feizizadeh & Blaschke (2013), Vukadinović i dr.(2014), Mustafa i dr.(2011), Yohannes & Soromessa (2018), Sarkar i dr.(2014), Ahamed i dr.(2000)
	Erozija	DMR	klasa	Akinci i dr.(2013), Vukadinović i dr.(2014), Kazemi & Akinci (2018), Yohannes & Soromessa (2018)
Ograničavajući faktori	Prometnice	OSM	-	Yohannes & Soromessa (2018), Sarkar i dr.(2014)
	Izgrađeno	DGU, OSM	-	Yohannes & Soromessa (2018), Sarkar i dr.(2014), Feizizadeh & Blaschke (2013)
	Travnjaci	n.k.	-	Yohannes & Soromessa (2018), Sarkar i dr.(2014), Akinci i dr.(2013)
	Trajni nasadi	OSM	-	-
	Vode	n.k., OSM	-	Sarkar i dr.(2014), Ahamed i dr.(2000)
	Šume	n.k.	-	Yohannes & Soromessa (2018), Sarkar i dr.(2014), Feizizadeh & Blaschke (2013), Akinci i dr.(2013)

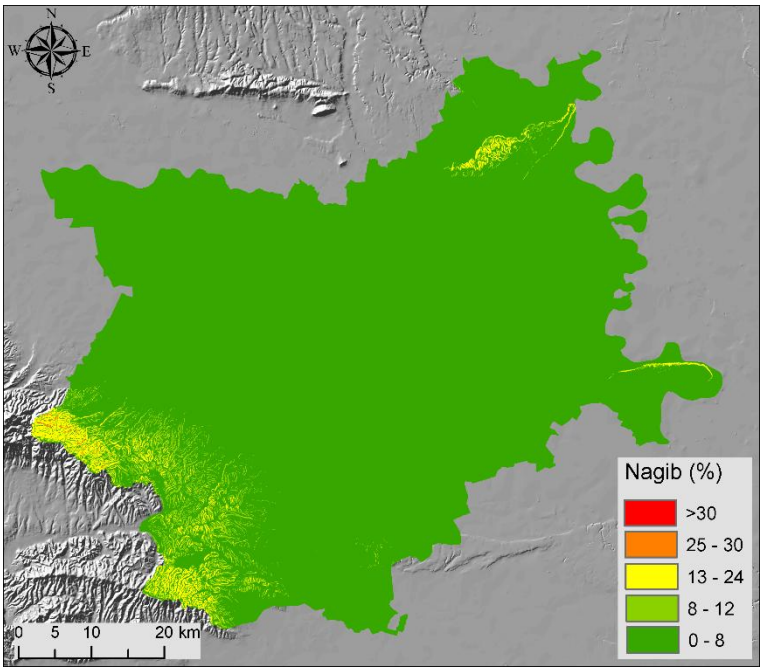
5.3.1. Geomorfometrijski kriteriji

Geomorfometrijski kriteriji su nadmorska visina, nagib i ekspozicija terena koji su izrađeni na osnovi izrađenog digitalnog modela reljefa. Nadmorska visina je manje relevantan kriterij u usporedbi s nagibom i ekspozicijom terena, s obzirom na to da dolazi do promjena u temperaturi s porastom visine (0,5°C na svakih 100 m) (Akinci i dr., 2013).



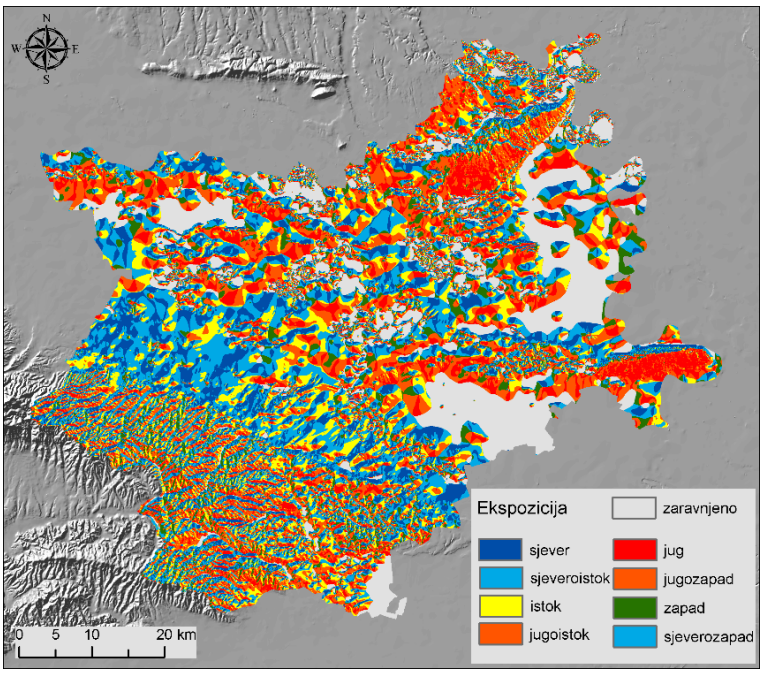
Slika 11. Hipsometrijska karta

Prostor Osječko-baranjske županije je vertikalno slabo raščlanjen s minimalnim vrijednostima visina od 80 metara i maksimalnim vrijednostima od 625 metara (Sl. 11). S obzirom na to da je granična vrijednost prve klase pogodnosti zemljišta na 1 500 metara (Tablica 5), očito je da je nadmorska visina manje relevantan kriterij. Nagib terena je bitan kriterij zbog toga što uvjetuje dubinu zemljišta, stupanj erozije, zadržavanje vode i drugo (Akinci i dr., 2013; Zhang i dr., 2015). Nagib terena generiran je iz DMR-a alatom *Slope* u *Spatial Analyst Tool* metodom *3x3 kvadrata* gdje se izračunava maksimalna promjena vrijednosti visina između središnje ćelije i okružujućih 8 ćelija (Šiljeg i dr., 2018). Osječko-baranjska županija je relativno zaravnjena, većina prostora je u klasi 0 do 8 % nagiba, a izraženiji nagibi se nalaze na jugozapadnom dijelu županije, na prostoru krndijskog osojnog pobrđa (Sl. 12).



Slika 12. Karta nagiba padina (prema Tablica 5.)

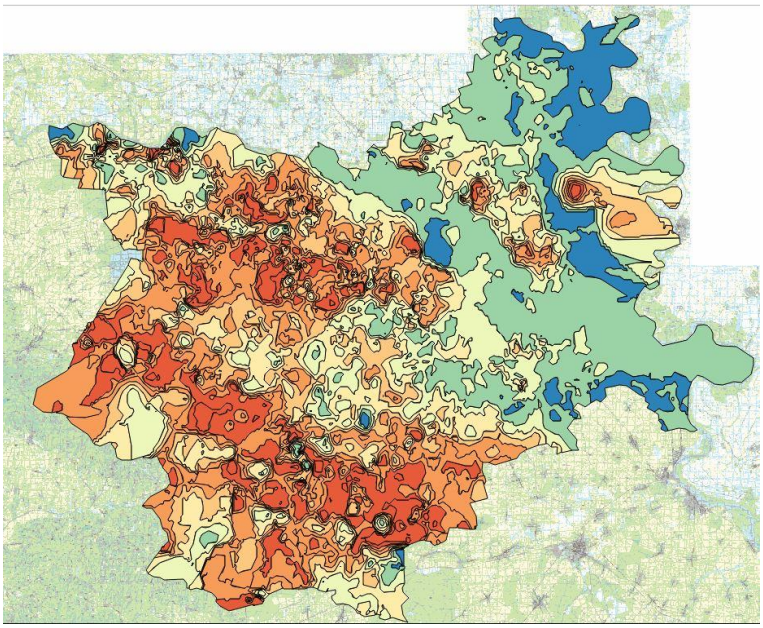
Ekspozicija predstavlja stranu svijeta na koju je okrenuta određena ploha, a kako je svim biljkama potrebno sunce za rast i razvoj, generalno gledano, južna, jugoistočna i jugozapadna ekspozicija su favorizirane jer predstavljaju prisojnu stranu padina (Akinci i dr., 2013). Kriterij ekspozicije generiran je na temelju izrađenog DMR-a alatom *Aspect* u *Spatial Analyst Tool* (Sl. 13) metodom *3x3 kvadrata* gdje smjer prema kojemu je okrenuta padina predstavlja ekspoziciju za središnji piksel modela (Šiljeg i dr., 2018).



Slika 13. Karta ekspozicije padina

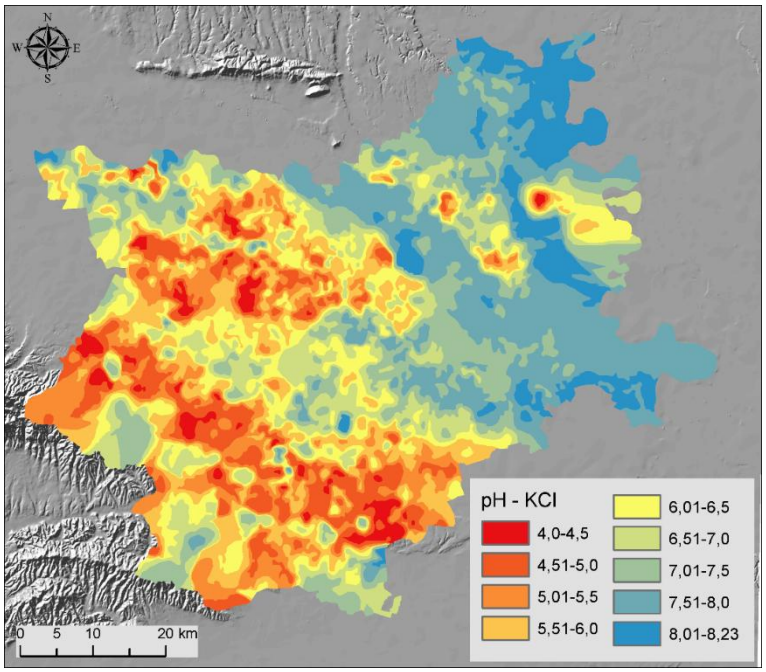
5.3.2. Pedološki kriteriji

Pedološki kriteriji su najvažniji kriteriji za izradu modela pogodnosti. Oni predstavljaju fizička i kemijska svojstva tla, a u njih se ubrajaju kiselost, tip i teksturu tla. Kiselost ili lužnatost tla izražava se pH vrijednošću (Sl. 15), a na nju može utjecati godišnja količina oborine te industrijsko zagađenje (Vukadinović i Vukadinović, 2018). U jako kiselim tlima dolazi do premještanja gline iz oraničnog sloja u dublje slojeve gdje dolazi do stvaranja vodonepropusnog sloja i daljnjeg zakiseljavanja tla te se smanjuje razgradnja organske tvari i sorptivna moć tla što uzrokuje smanjenu proizvodnu moć tla (Vukadinović i Vukadinović, 2018). Optimalne vrijednosti pH tla za uzgoj ječma kreću se od 6,2 do 7,5 (Tablica 5).

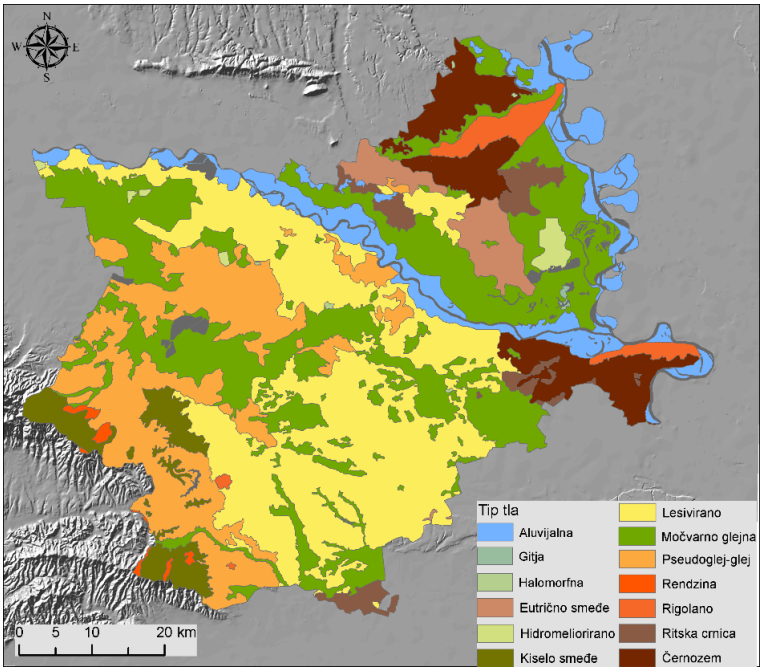


Slika14. Izvorna karta pH vrijednosti (URL 9)

Kriterij tipa tla izvezen je iz pedološke karte Republike Hrvatske alatom *Clip* samo za područje Osječko-baranjske županije gdje je izdvojeno 25 različitih tipova tla. Najveću površinu tala zauzimaju djelomično hidromeliorirana močvarno glejna, lesivirana na praporu i aluvijalna tla (oko 50 % površine cijele županije) (Sl. 16). Što se tiče pogodnosti tla, najpogodnija zastupljena tla su aluvijalna, aluvijalno-livadna, černozem na praporu i eutrično smeđa tla (Husnjak i Bensa, 2018; Bogunović i dr., 1997) koja zauzimaju površinu od oko 70 000 ha. Naravno, uz tip tla usko je vezan kriterij teksture tla jer nemaju sva tla istu teksturu. Nakon što je izdvojen sloj tipa tla, njemu su pridodana svojstva teksture, za svaki tip tla posebno.

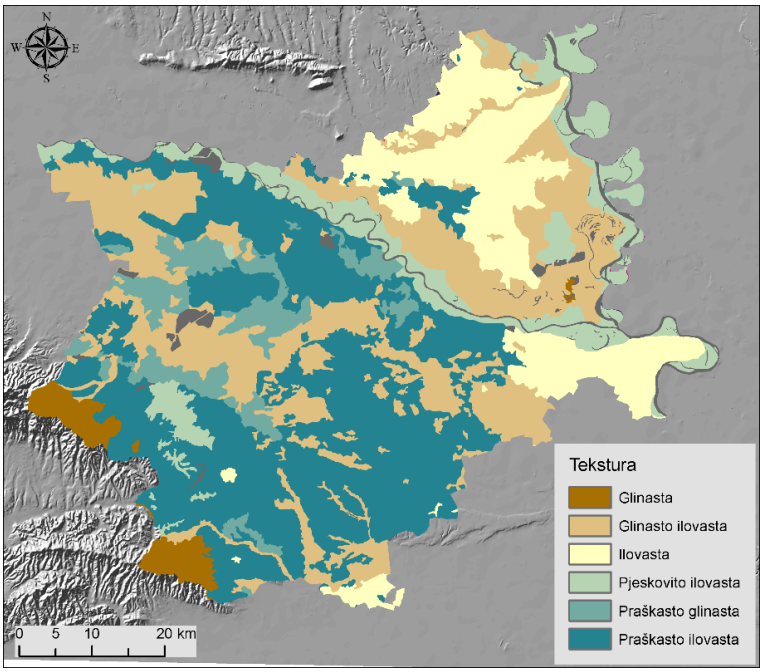


Slika 15. Karta pH-KCl vrijednosti tla



Slika 16. Karta tipova tla

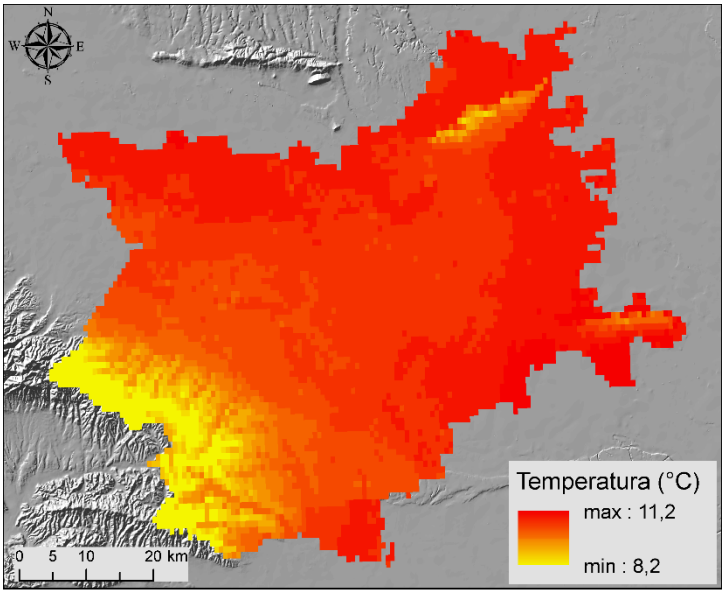
Klase teksture tla određene su na temelju proučavane literature (Husnjak, 2014), a one mogu biti: praškasto ilovasta, praškasto glinasta, pjeskovito ilovasta, ilovasta, glinasto ilovasta i glinasta (Sl. 17). S obzirom na to da je ječmu potrebna dobra ocjeditost tla zaključno je da je najpogodnija tekstura ilovasta i pjeskovito ilovasta.



Slika 17. Karta teksture tla

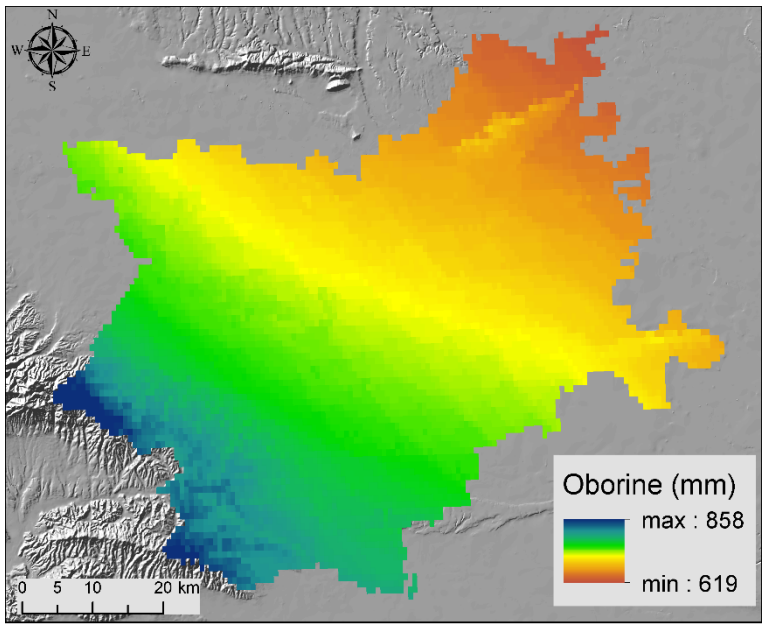
5.3.3. Klimatski kriteriji

Na temelju srednjih mjesečnih temperatura za prostor Osječko-baranjske županije generiran je podatak za cijelu godinu alatom *Raster calculator* u *ArcMap-u*. Prosječna godišnja temperatura kreće se od 8,2°C do 11,2°C (Sl. 18) iz čega se može zaključiti da su temperature vrlo pogodne za uzgoj ječma jer su optimalne temperature za razvoj ječma od 10°C do 12°C (Tablica 5).



Slika 18. Prosječna godišnja temperatura Osječko-baranjske županije

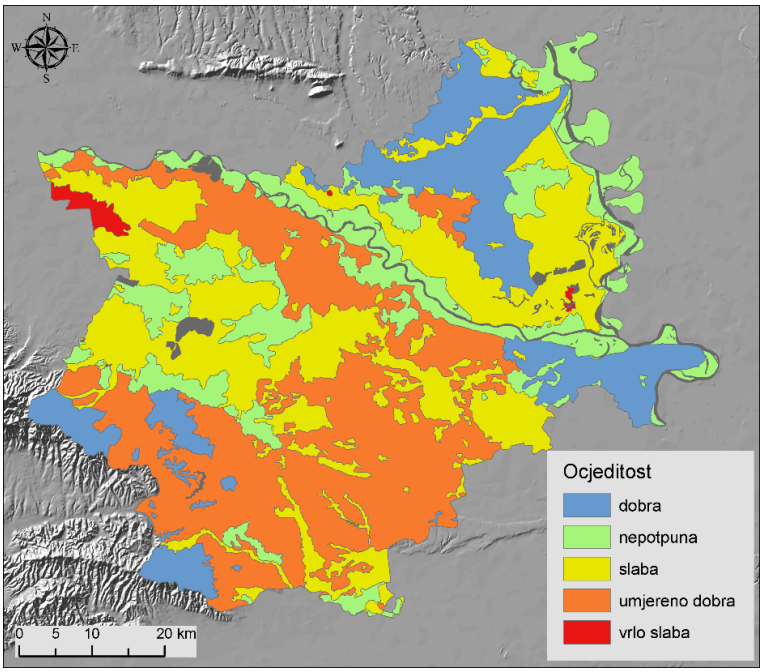
Kriterij oborine generiran je na isti način kao kriterij temperature: alatom *Raster calculator* zbrojene su sve mjesečne količine oborina i podijeljene s 12. Oborine su zonalno raspoređene, od jugozapada prema sjeveroistoku, minimalne vrijednosti 619 mm/god, maksimalne vrijednosti 858 mm/god te su ravnomjerno raspoređene kroz godinu, bez većih odstupanja (Sl. 19). Iz toga se zaključuje kako je prostor Osječko-baranjske županije po kriteriju oborina većim dijelom u drugoj, a manjim dijelom u prvoj kategoriji pogodnosti (Tablica 5).



Slika 19. Prosječna godišnja količina oborina Osječko-baranjske županije

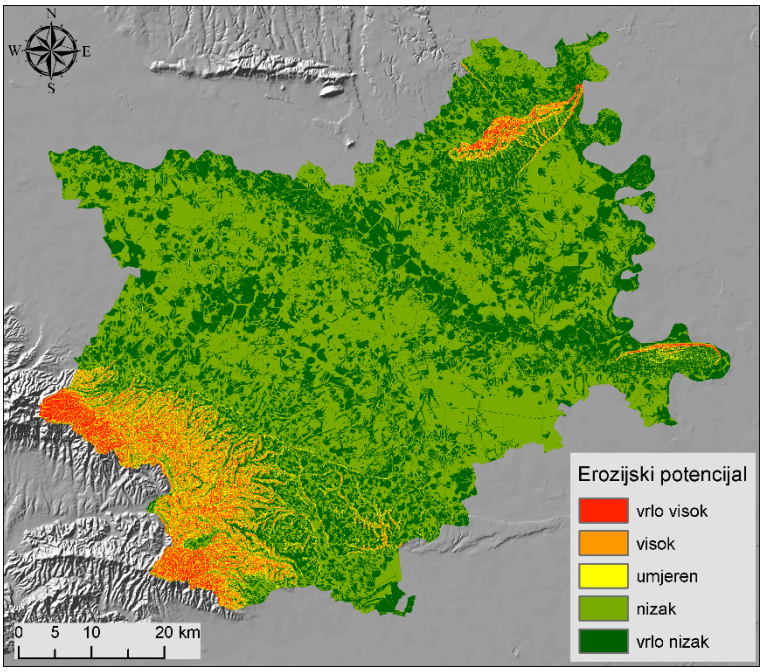
5.3.4. Hidrološki kriteriji

Hidrološki kriteriji usko su vezani uz kriterij nagiba i teksture tla, stoga su im pridodane slične vrijednosti pri određivanju težinskih koeficijenata. Podaci o ocjeditosti terena dobiveni su na temelju proučene literature, a ocjeditost ovisi o teksturi i nagibu tla (Husnjak, 2014). Klase ocjeditosti terena su: dobra, umjereno dobra, nepotpuna, slaba i vrlo slaba ocjeditost (Sl. 20). Iz karte ocjeditosti terena vidljivo je kako su područja s dobrom i umjereno dobrom ocjeditošću ona koja se nalaze na reljefno izraženijim i nagnutijim terenima, a područja s nepotpunom i slabom ocjeditošću ona u zaravnjenim dijelovima i uz vodotoke.



Slika 20. Karta ocjeditosti terena

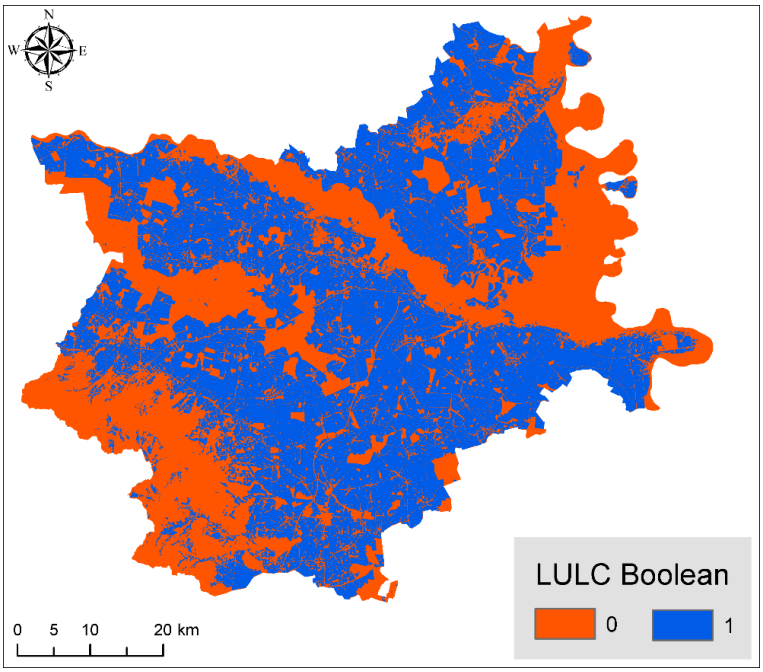
Erozija zemljišta dobivena je na temelju izrađenog modela pogodnosti erodiranju materijala. Model je napravljen na temelju 10 izrađenih kriterija u programima *SAGA GIS* i *ArcMap 10.1*: nagib padine, orijentacija, planarna zakrivljenost, profilna zakrivljenost, LS faktor (faktor duljine nagiba i strmine), topografski indeks vlažnosti, indeks snage toka, površina slijeva jaruge, vegetacijski pokrov, pedološki pokrov i ograničavajući faktori (Domazetović, 2018) (Sl. 21). Metodologija izrade ovog modela je objavljena u diplomskom radu *Kvantitativne analize jaruga na prostoru otoka Paga korištenjem modela visoke rezolucije* Frana Domazetovića. Najveći težinski koeficijent imao je kriterij nagiba, stoga se može zaključiti da je najveća pogodnost erodiranju tereni s najvećim nagibom i s najmanje vegetacije. S obzirom na to da je Osječko-baranjska županija relativno zaravnjena, s nagibima najvećim dijelom 0 – 6 %, kriterij erozije nije izražen i stoga nema veliki težinski koeficijent, ali nije isključiv.



Slika 21. Karta erozijskog potencijala Osječko-baranjske županije

5.3.5. Ograničavajući faktori

Ograničavajući faktori predstavljaju područja na kojima nije moguće koristiti zemljište u svrhu poljoprivredne proizvodnje. Oni su generirani na temelju nadzirane klasifikacije satelitskih snimaka *Sentinel 2*, dostupnih podataka o prometnicama i geoobjektima s *Open Street Map*-a, WMS servera Državne geodetske uprave i WMS servera Agencije za zaštitu okoliša. Na temelju svih izrađenih podataka dobiveni su ograničavajući faktori koji će imati težinski koeficijent 0 u modelu pogodnosti, odnosno izrađeni su na principu *Boolean* pristupa (Sl. 22). *Boolean* pristup temelji se na binarnom sustavu, što znači da vrijednosti mogu biti 0 ili 1. Vrijednosti 0 označavaju sve one površine na kojima ne može doći do uzgoja ječma (ograničavajući faktori), a vrijednosti 1 predstavljaju površine na kojima je moguć uzgoj (poljoprivredne površine).



Slika 22. Karta ograničavajućih faktora (Boolean pristup)

Tablica 5. Raspon pogodnosti po klasama

	Kriteriji	Raspon pogodnosti				
		S1	S2	S3	N1	N2
Geomorfom.	Nadmorska visina	0 – 1500 m	1500 – 2300 m	2300 – 3300 m	3300 – 3800 m	>4500 m
	Nagib	0 – 8%	8 – 16%	16 – 24%	24 – 30%	>30%
	Ekspozicija	Jug	Istok	Zapad	Sjever	-
Pedološki	Kiselost tla	6,2 – 7,5	<6,2 – 5,8 ; >7,5 – 8,0	<5,8 – 5,5 ; >8,0 – 8,5	-	<5,5 ; >8,5

	Tip tla	Černozem, Aluvijalno, Eutrično smeđe (na holocenskim nanosima)	Arenosol antropogenizirani, Lesivirano (prapor, rastresiti sedimenti, ilovača), Rigolano (prapor, lapor)	Eutrično smeđe (sedimenti), Distrično smeđe (prapor, klasiti), Koluvij (prevaga detritusa,sitnice), Rendizina (šljunku, flišu, laporu), Rigolano krša, Sirozem (laporu, praporu)	Gitja	Crnica vap.dolomitna, Eutrično smeđe (eruptivi), Kamenjar, Lesivirano (dolomit, vapnenac), Podzol, Ranker humusno silikatni (pješčenjak), Smeđe (dolomit, vapnenac)
	Tekstura tla	Glinasto ilovasta, ilovasta, praškasto ilovasta	Pjeskovito glinasta, pjeskovito ilovasta	Pjeskovito ilovasta, ilovasto pjeskovita	-	Praškasto glinasta, glinasta
Klimatski	Temperatura	10 – 12 °C	6-8 ; 12-18 °C	4-6 ; 18-24 °C	2-4 : 24-28 °C	<2 ; >28 °C
Klimatski	Oborine	400-650 mm	300-400 ; 650-900 mm	200-300 ; 900-1300 mm	200-150 ; 1300-1500 mm	<150 ; >1500 mm
Hidrološki	Ocjeditost	Dobra	Umjereno dobra	Nepotpuna – slaba	Slaba	Vrlo slaba
Hidrološki	Erozija	Vrlo nisko	Nisko	Umjereno	Visoko	Vrlo visoko

Izvor: (Yohannes i Soromessa, 2018; Sys i dr., 1991; Sys i dr., 1993; Ennaji i dr., 2018; FAO, 1976; Husnjak i Bensa, 2018)

5.4. STANDARDIZIRANJE KRITERIJA

Nakon što su određeni kriteriji i prikupljeni podaci, sve je potrebno standardizirati na jednake vrijednosti kako bi se ti podaci mogli uspoređivati (Malczewski i Rinner, 2015) i koristiti u izradi modela nakon što im se odrede težinski koeficijenti. Stupanj pogodnosti zemljišta izrađen je na temelju FAO-ve klasifikacije poljoprivrednog zemljišta koja obuhvaća 5 klasa pogodnosti: S1, S2, S3, N1 i N2 (FAO, 1976). FAO (*Food and Agricultural Organization*) preporučuje pristup ocjenjivanju pogodnosti zemljišta za usjeve u smislu ocjena pogodnosti unutar 5 klasa koje su dobivene na temelju klimatskih, gemorfometrijskih i

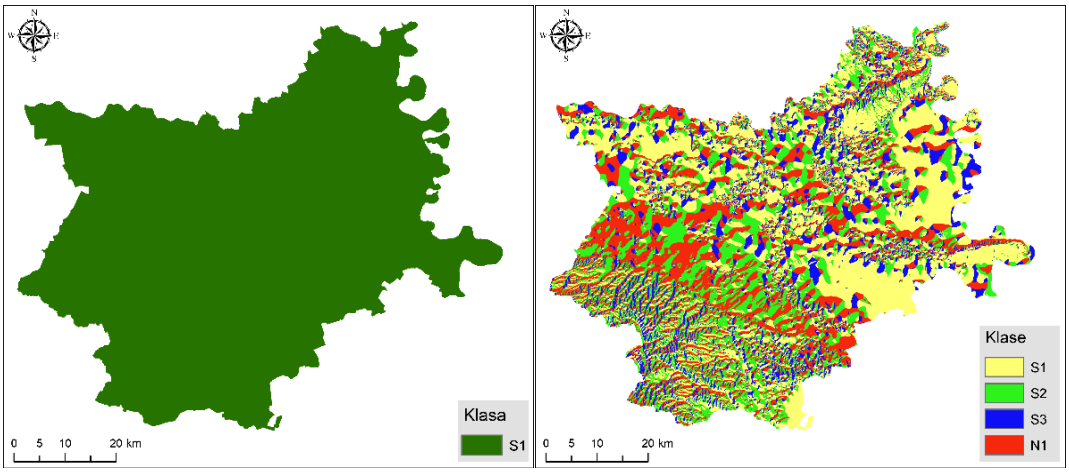
pedoloških svojstava tla za usjeve (Ahamed i dr., 2000). Na temelju te klasifikacije, izvršena je standardizacija kriterija od 1 do 5 naredbom *Reclassify* (*Spatial analyst tool*) u programu *ArcMap 10.1* (Yohannes i Soromessa, 2018) gdje svaka klasa predstavlja pripadajuću FAO-vu klasu pogodnosti poljoprivrednog zemljišta. Svaka klasa ima svoj raspon vrijednosti (Tablica 5) i prema tome su određene vrijednosti kriterija pridodane FAO klasama.

Tablica 6. Klase pogodnosti poljoprivrednog zemljišta

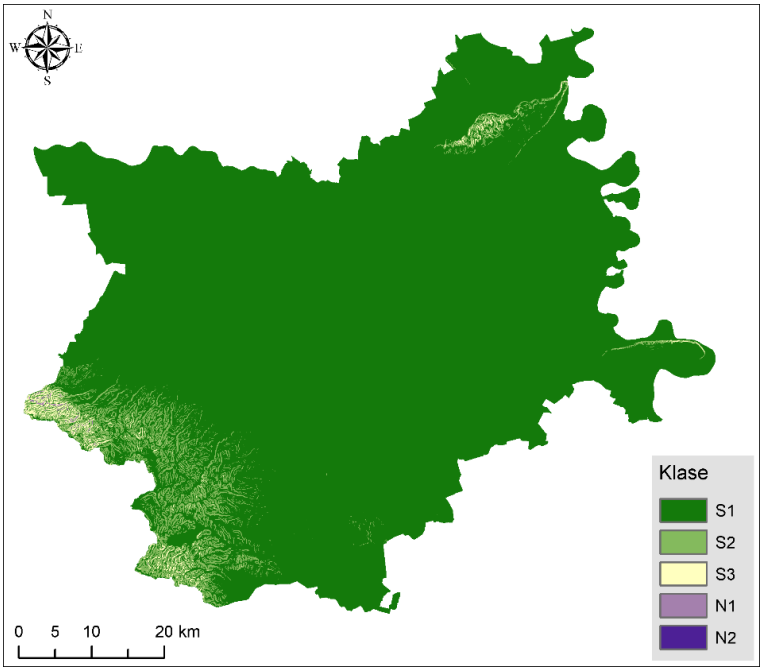
Klase pogodnosti	Naziv klase	Opis klase
S1	Vrlo pogodna	Zemljišta koja nemaju značajna ograničenja za trajnu uporabu
S2	Umjereno pogodna	Zemljište koje ima ograničenja koja su u ukupnoj mjeri umjereno pogodna za kontinuiranu uporabu
S3	Marginalno pogodna	Zemljišta koja imaju ograničenja koja su ozbiljna za neprekidnu uporabu i tako će smanjiti produktivnost ili koristi
N1	Trenutno nepogodna	Zemljišta koja imaju ograničenja koja mogu biti otklonjena s vremenom, ali ograničenja su toliko ozbiljna da onemogućuju uspješno trajno korištenje zemljišta na zadani način
N2	Trajno nepogodna	Zemljišta koja imaju ograničenja koja sprječavaju bilo kakve mogućnosti za uspješno trajno korištenje zemljišta na zadani način

Izvor: (FAO, 1976)

Vrijednosti kriterija nadmorske visine kreću se od 80 do 625 metara. S obzirom na to da je za standardizaciju kriterija korištena FAO-va klasifikacija, kriterij nadmorske visine, za cijeli prostor Osječko-baranjske županije svrstan je u klasu S1 (Sl. 23). Vrijednosti kriterija nagiba kreću se od 0 do 31,71 %, stoga je nagib standardiziran u 5 klasa (Sl. 24). Prva klasa je najzastupljenija, a njene vrijednosti kreću se od 0 do 8 % nagiba terena što predstavlja najpogodnije vrijednosti nagiba (Sys i dr., 1993). Veći nagibi javljaju se u brdskim i gorskim prostorima, na sjeveroistočnoj i jugozapadnoj strani županije. Vrijednosti kriterija ekspozicije padine kreću se od -1 do 360°, gdje vrijednosti od -1 do 0° predstavljaju zaravnjene plohe (vodene površine), a od 0 do 360° predstavljaju strane svijeta. Ekspozicija je standardizirana u 4 klase koje predstavljaju glavne strane svijeta (jug, istok, zapad i sjever) (Sl. 23). Kao što je već navedeno, južna strana padine je prisojna, stoga je pogodnija za biljni uzgoj (Mustafa i dr., 2011).

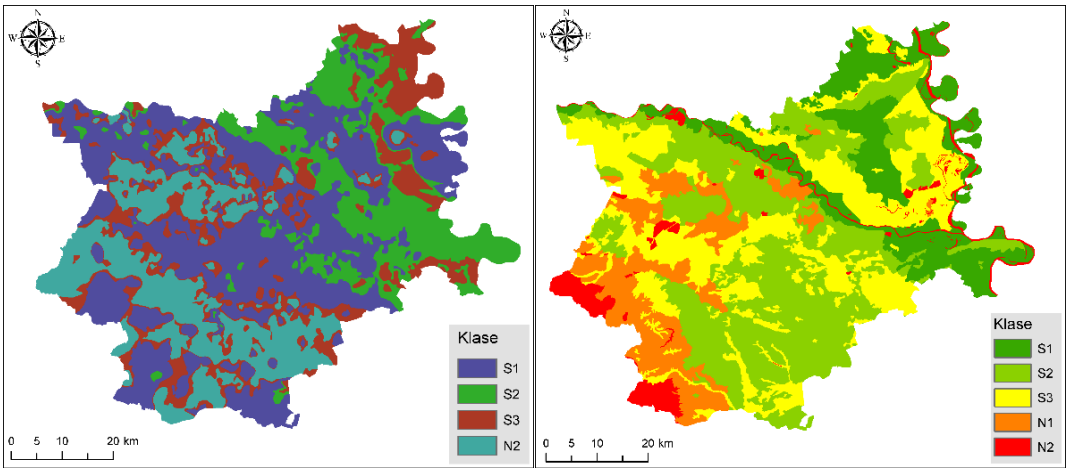


Slika 23. Standardizirani kriteriji nadmorske visine (lijevo) i ekspozicije (desno)

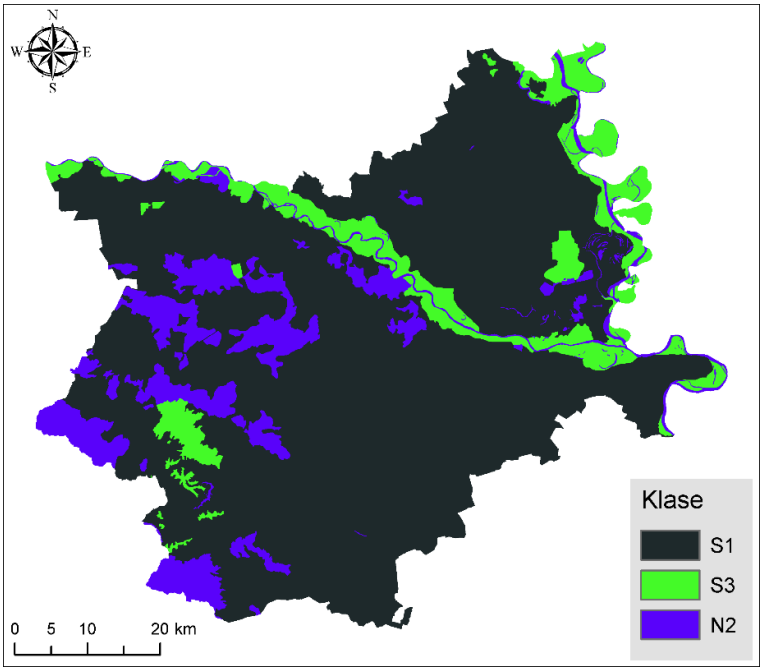


Slika 24. Standardizirani kriterij nagiba

Vrijednosti kriterija kiselosti tla kreću se od pH 4,0 do pH 8,23, a standardizirane su u 4 klase (Sl. 25). Najpogodnije vrijednosti pH su od 6,2 do 7,5 što predstavlja prvu klasu. Kriterij tip tla sadržava 25 različitih vrsta tala. Prema literaturi, tipovi tla su svrstani u 5 klasa koje predstavljaju FAO-ve klase pogodnosti poljoprivrednog zemljišta te su na temelju toga standardizirani u 5 klasa, odnosno vrijednostima od 1 do 5 (Sl. 25). Vrijednosti teksture tla standardizirane su u 3 klase od kojih je najpogodnija klasa s glinasto ilovastom, ilovastom i praškasto ilovastom teksturom (Sl. 26).

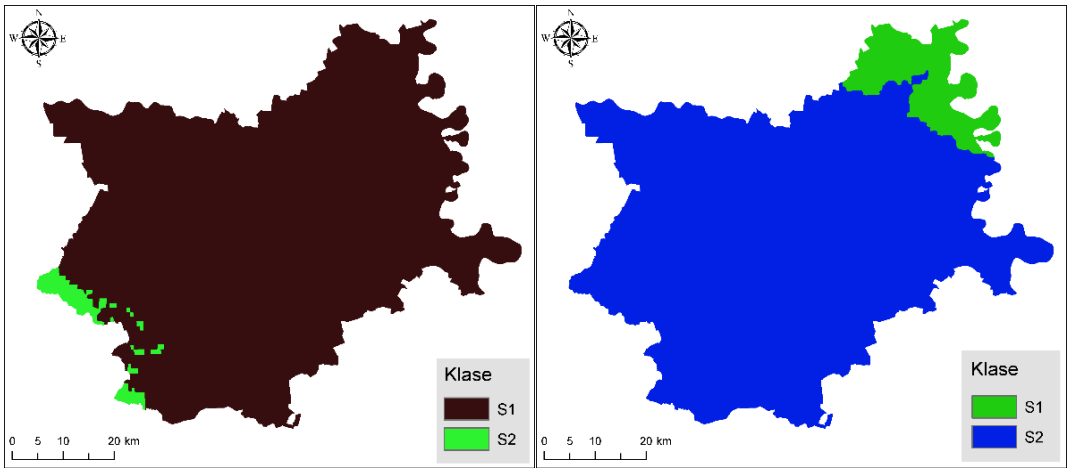


Slika 25. Standardizirani kriteriji pH (lijevo) i tipa tla (desno)



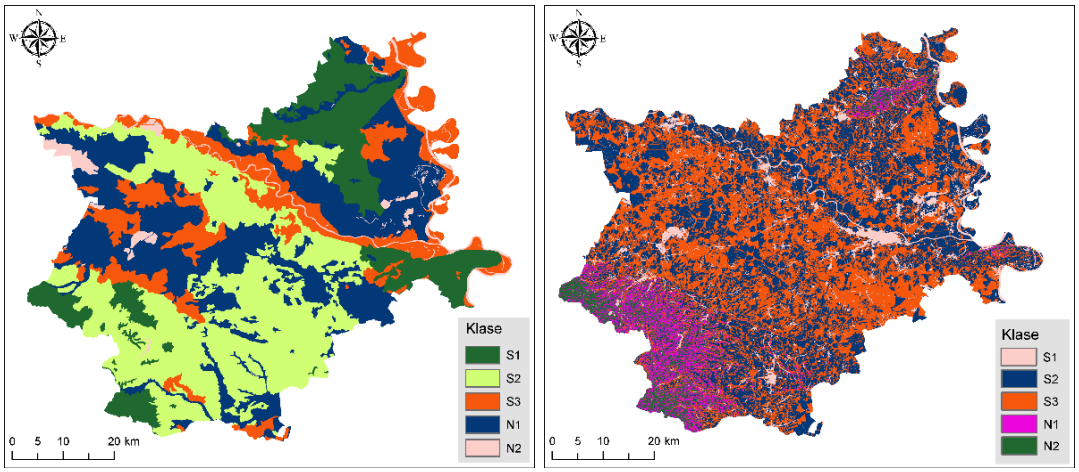
Slika 26. Standardizirani kriterij teksture tla

Vrijednosti srednje godišnje temperature kreću se od 8,2 do 11,2°C. Te vrijednosti standardizirane su u dvije klase. Prva klasa su vrijednosti od 10 do 12°C, a druga su vrijednosti manje od 10°C (Sl. 27). Većina površine Osječko-baranjske županije spada u prvu klasu, dok su vrijednosti druge klase zastupljene samo na većim nadmorskim visinama na jugozapadu županije. Prosječne godišnje količine oborina kreću se od 619 do 858 mm, stoga su vrijednosti standardizirane u dvije klase: prva klasa je od minimalne vrijednosti do 650 mm, druga klasa je preko 650 mm (Sl. 27). Sjeveroistočni dio županije pripada prvoj klasi dok ostatak županije pripada drugoj klasi.



Slika 27. Standardizirani kriteriji temperature (lijevo) i oborina (desno)

Vrijednosti ocjeditosti terena su standardizirane u 5 klasa, gdje prvoj klasi pripadaju zemljišta dobre ocjeditosti, druga klasa je umjereno dobra ocjeditost, treća je nepotpuna ocjeditost, četvrta je slaba i peta je vrlo slaba ocjeditost (Sl. 28). Vrijednosti erozijskog potencijala kreću se od 0 do 5, gdje su vrijednostima od 0 do 1 izraženi prostori na kojima nije moguća erozija (vodene površine i izgrađeno). Kriterij erozije terena standardiziran je od 1 do 5, gdje klasa 1 predstavlja prostore na kojima je najveći potencijal za erodiranje materijala što predstavljaju veći nagibi (Sl. 28).



Slika 28. Standardizirani kriteriji ocjeditosti (lijevo) i erozije (desno)

5.5. ODREĐIVANJE TEŽINSKIH KOEFICIJENATA

Nakon standardizacije kriterija potrebno je odrediti težinske koeficijente koji pridodaju važnost svakom tom kriteriju i time utječu na završni model (Malczewski, 2004).

Za određivanje težinskih koeficijenata odabrana je metodologija *Analitičkog procesa hijerarhije* (AHP) koja je prethodno objašnjena u poglavlju *Kvantitativne analize*.

Kako bi se odredili težinski koeficijenti kriterija, prvo je potrebno izraditi matricu u kojoj će se kriteriji uspoređivati metodom „parne usporedbe". Za određivanje relativne važnosti kriterija ovom metodom koristi se brojčana skala od 1/9 do 9 (Satty, 2008). Pridodane vrijednosti svakom kriteriju u matrici donesene su na temelju proučavane literature (Mustafa i dr., 2011; Ahamed i dr., 2000; Feizizadeh i Blaschke, 2013; Yohannes i Soromessa, 2018; Akinci i dr., 2013; Zhang i dr., 2015). Nakon što su pridodane vrijednosti relativne važnosti, izračunate su vrijednosti težinskih koeficijenata za svaki kriterij koje će se koristiti za vrednovanje kriterija u izradi modela pogodnosti poljoprivrednog zemljišta za uzgoj ječma.

Tablica 7. Matrica „parne usporedbe" intenziteta vrijednosti kriterija

Kriterij	Geomorfometrijski			Pedološki			Klimatski		Hidrološki		Težinski
	NMV	Nagib	Eksp.	pH	Tip	Teks.	Temp.	Pada.	Dren.	Eroz.	koef.
NMV	1	1/7	1/3	1/7	1/9	1/7	1/3	1/5	1/3	1/3	0,0183
Nagib	7	1	3	1/3	1/5	1/3	4	3	1	1	0,0924
Eksp.	3	1/3	1	1/4	1/5	1/3	1/2	1/3	1/3	1	0,0382
pH	7	3	4	1	1/3	1/2	5	3	3	3	0,1531
Tip	9	5	5	3	1	3	7	5	3	5	0,2875
Teks.	7	3	3	2	1/3	1	4	2	3	3	0,1598
Temp.	3	1/4	2	1/5	1/7	1/4	1	1/3	1/4	1/3	0,03548
Pada.	5	1/3	3	1/3	1/3	1/2	3	1	1	3	0,0809
Dren.	3	1	3	1/3	1/3	1/3	4	1	1	2	0,0811
Eroz.	3	1	1	1/3	1/5	1/3	3	1/3	1/2	1	0,0528
Lmax = 10,9795				CI = 0,1088				CR = 0,0730			∑=1

5.6. AGREGIRANJE KRITERIJA

Kada su određeni težinski koeficijenti kriterijima, tada ih je potrebno agregirati u jednu cjelinu. Prilikom okupljanja kriterija, svaki pojedinačni kriterij stvara vlastitu hijerarhiju (podhijerarhiju) elemenata problema odluke (Malczewski i Rinner, 2015). Potrebno je objediniti sve kriterije kako bi se pronašla najbolja alternativa rješavanja

problema. To se vrši metodom geometrijskog srednjaka prema formuli (Malczewski i Rinner, 2015) :

$$A = \sum wi\ Xi * \prod Cj$$

A = pogodnost ∑ = suma ponderiranih kriterija

Wi = težinski koeficijent kriterija Xi = vrijednost kriterija

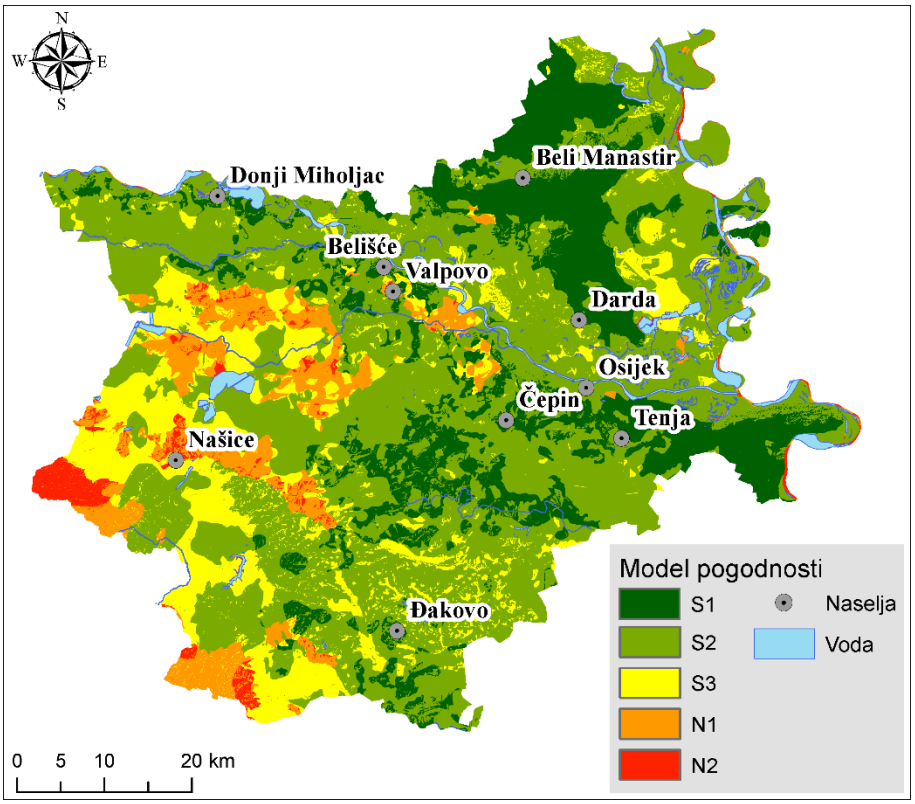
∏Cj = umnožak ograničenja

Agregiranje kriterija izrađeno je alatom *Raster calculator* u programu *ArcMap*. Okupljenim kriterijima dodane su vrijednosti ograničavajućih faktora te je izlazni rezultat model pogodnosti.

Nakon toga, model pogodnosti (Sl. 29) je reklasificiran u 5 klasa metodom *jednakih intervala* zbog toga što su vrijednosti kriterija bile standardizirane prema FAO-vim klasama pogodnosti (Akinci i dr., 2013).

Tablica 8. Zemljišni indeks FAO klasa pogodnosti

FAO klasa	Naziv klase	Zemljišni indeks
S1	Vrlo pogodna	100 – 80
S2	Umjereno pogodna	80 – 60
S3	Marginalno pogodna	60 – 40
N1	Trenutno nepogodna	40 – 20
N2	Trajno nepogodna	20 - 0



Slika 29. Model pogodnosti poljoprivrednog zemljišta za uzgoj ječma

5.7. PROVJERA REZULTATA

Nakon što je izrađen model pogodnosti poljoprivrednog zemljišta za uzgoj ječma, potrebno je izvršiti provjeru modela, odnosno provjeriti koliko izrađeni model odstupa od stvarnog stanja. Provjera modela pogodnosti može se izvršiti iz dva pristupa :

1. Provjera modela pogodnosti s obzirom na površine zasijane ječmom

2. Provjera modela pogodnosti s obzirom na NDVI indeks vegetacije

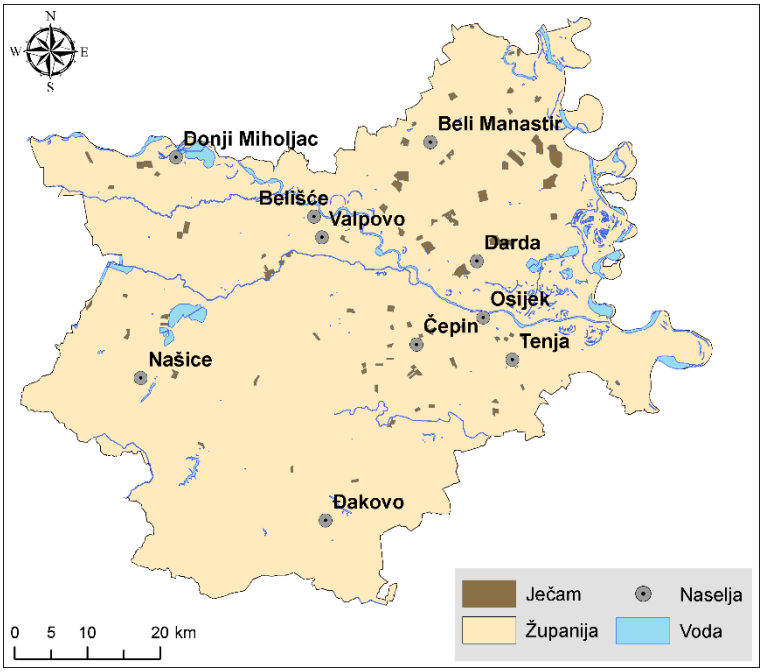
S obzirom na to da se oba pristupa podudaraju u velikoj mjeri, može se zaključiti da su oba pristupa validna i daju pozitivne rezultate.

5.7.1. Prvi pristup

Kako bi se izradila provjera modela pogodnosti, potrebni su podaci o lokacijama na kojima je zasijan ječam na prostoru Osječko-baranjske županije. U suradnji s pročelnicom upravnog odjela za poljoprivredu Osječko-baranjske županije, gospođom Silvom Wendling i *Agencijom za plaćanje u poljoprivredi, ribarstvu i ruralnom razvoju* (APPRRR), dobiveni su

zatraženi podaci o parcelama na kojima je zasijan ječam na prostoru Osječko-baranjske županije.

Na temelju ustupljenih podataka, preko internetskog web-preglednika ARKOD-a (URL 17) izvedene su katastarske čestice na kojima je zasijan ječam (Sl. 30). Te katastarske čestice su preklopljene s izrađenim modelom pogodnosti te su iz modela izdvojeni samo prostori na kojima su te čestice naredbom *Clip* (*Data Management tools*). Dobiveni podatak je potrebno prebaciti u vektorski sloj kako bi mu se mogle izračunati površine po klasama pogodnosti, a to je izrađeno alatom *Raster to polygon*. Nakon toga, naredbom *Dissolve* (*Data Management tools*) izračunate su ukupne površine prostora na kojima je zasijan ječam po klasama pogodnosti te je izračunat udio tih površina po klasama pogodnosti (Tablica 9).



Slika 30. Karta parcela pod ječmom

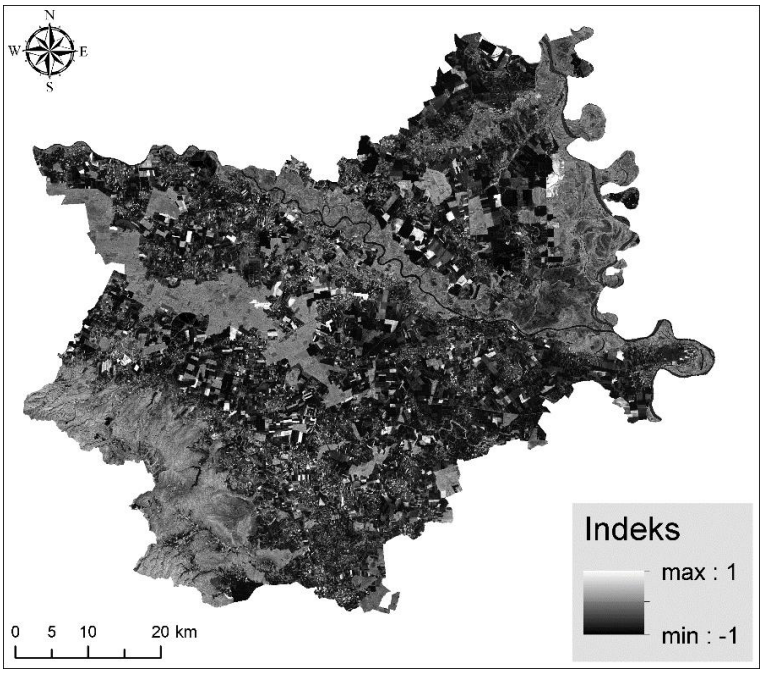
Tablica 9. Ukupna površina i udio parcela pod ječmom prema klasama pogodnosti

Ukupna površina parcela (ha)		Udio (%)
S1	1395,95	27,93
S2	2843,81	56,89
S3	437,41	8,75
N1	317,76	6,36
N2	3,96	0,08
Ukupno	4998,95	100

S obzirom na generirane podatke, jasno se može vidjeti da se, površine na kojima je zasijan ječam, nalaze preko 90 % u pogodnim klasama pogodnosti (preko 4 500 ha površine) iz čega se zaključuje da je izrađen model visoke točnosti.

5.7.2. Drugi pristup

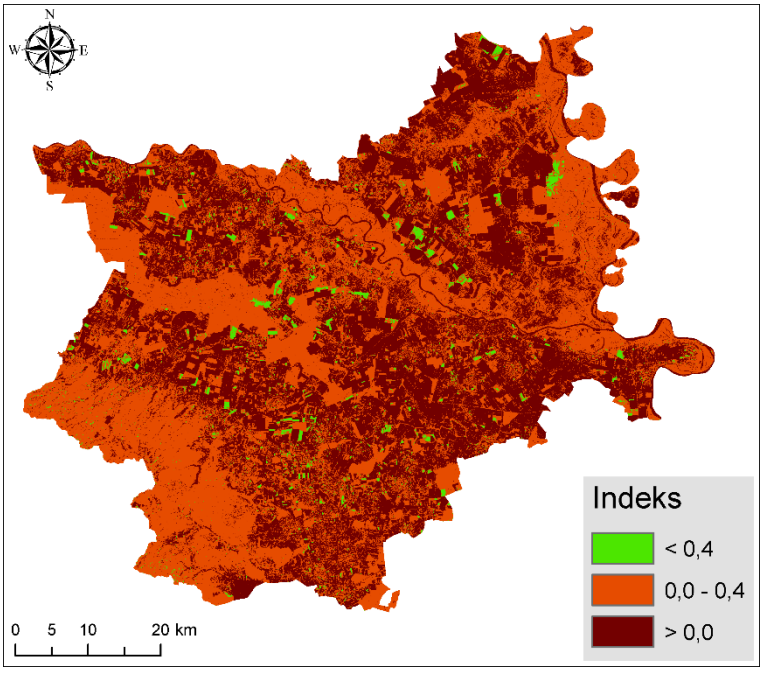
Bez točnih podataka o lokacijama na kojima je zasijan ječam, koristio bi se drugi pristup provjere modela pogodnosti. Drugi pristup se bazira na analizi NDVI indeksa zdravlja vegetacije i podacima o traženim kulturama po jedinstvenom zahtjevu. Podaci o prijavljenim uzgajivačima ječma u Republici Hrvatskoj dostupni su na internetskoj stranici *Agencije za plaćanja u poljoprivredi, ribarstvu i ruralnom razvoju* (URL 11) gdje je za svako naselje posebno upisan broj i vrsta poljoprivrednih gospodarstava, poljoprivredna kultura koju uzgaja gospodarstvo te površina na kojoj se uzgaja ta kultura. Podaci za kulturu ozimog ječma pridodani su sloju *Općine* u *ArcMap*-u kako bi se dobio podatak površina na kojima se uzgaja ječam po općinama. Na temelju tih podataka, izrađeni kartogram je preklopljen s modelom pogodnosti te je iz analize vidljivo da su najveće površine zatražene na područjima S1 i S2 klasa pogodnosti. Također, navedeni podatak je potrebno preklopiti sa NDVI indeksom zdravlja vegetacije.



Slika 31. NDVI indeks vegetacije

Za prostor Osječko-baranjske županije izrađen je indeks zdravlja vegetacije (NDVI) u programu *Erdas Imagine 2014* na temelju satelitskih snimaka *Sentinel 2* potraženih za datum

6. studenoga 2018. godine (Sl. 31). Tim NDVI indeksom, na navedeni se datum pokušalo utvrditi područje na kojemu je zasijan ozimi ječam iz tri razloga. Prvi razlog je taj što zbog velike naoblake početkom listopada 2018. godine, nije bilo moguće izvršiti detaljnije analize zdravlja vegetacije kako bi se popratio razvoj zasijanih (ozimih) kultura. Drugi razlog je to što se jari ječam sije u proljeće, kada dolazi do jačeg razvoja vegetacije te bi to stvaralo poteškoće pri određivanju površina zasijanih ječmom jer je tada NDVI indeks općenito visok. Treći razlog je to što će za potraženi datum NDVI indeks između zdrave vegetacije (one u razvoju) i ostale vegetacije (šume, livade, poljoprivredne površine) biti izraženiji, što će utjecati na realnije izlazne rezultate. S obzirom na to da se ozimi ječam sije početkom listopada, na datum 6. studenoga, ječam je bio u vegetativnoj fazi busanja ili početnoj fazi vlatanja (URL 12), stoga je NDVI indeks ječma visok. Kako nemaju sve poljoprivredne kulture jednake fenofaze i razdoblje kada se siju, usporedbom izrađenog NDVI indeksa može se pretpostaviti da se ječam, kao i druge ozime kulture, nalazi na prostoru gdje se nalaze visoke vrijednosti NDVI indeksa. NDVI indeks je reklasificiran u 3 klase gdje najveće vrijednosti klase iznose 0,4 i više što predstavlja visoke vrijednosti zdravlja vegetacije (URL 13) (Sl. 32). Iz analize je utvrđeno da se gotovo sve visoke vrijednosti NDVI indeksa nalaze unutar prve, druge i treće klase pogodnosti, no vrijednosti unutar četvrte i pete klase mogu predstavljati neku drugu ozimu kulturu (npr. uljanu repicu).



Slika 32. Reklasificirani NDVI indeks vegetacije

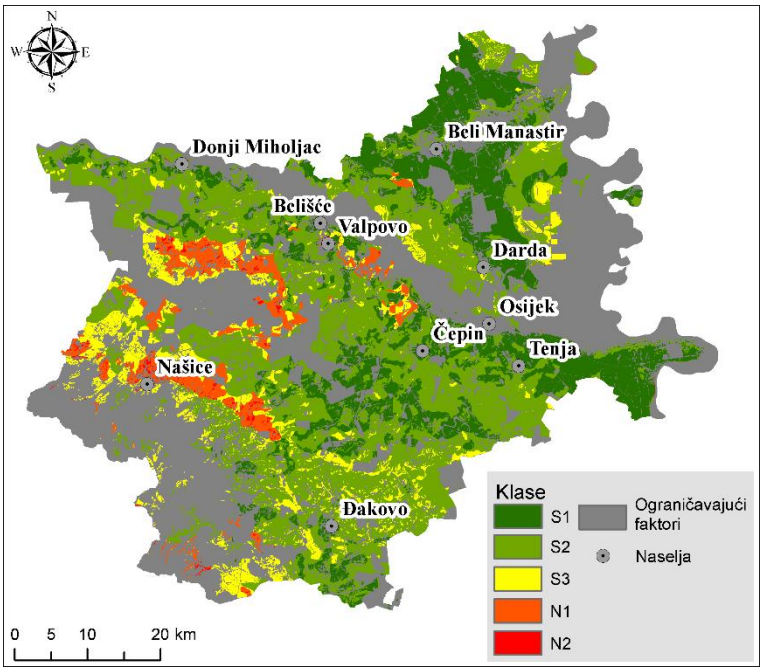
Nakon toga, reklasificirani rasterski podatak NDVI indeksa je naredbom *Raster to Polygon* (*Conversion tools*) pretvoren u vektorski podatak iz kojega su izvezeni svi poligoni prve klase (NDVI > 0,4), odnosno poligoni koji predstavljaju područja zdrave vegetacije. Ti poligoni su preklopljeni s izrađenim modelom pogodnosti te je izračunata površina zdrave vegetacije po klasama pogodnosti (Tablica 10).

Tablica 10. Udio NDVI > 0,4 indeksa prema klasama pogodnosti

	Površina NDVI > 0,4 (ha)	Udio (%)
S1	1342,10	19,19
S2	4027,85	57,58
S3	848,83	12,13
N1	692,96	9,91
N2	83,19	1,19
Ukupno	6994,93	100

6. MODEL POGODNOSTI – REZULTATI

Model pogodnosti poljoprivrednog zemljišta za uzgoj ječma izrađen je na temelju 10 kriterija, koji su podijeljeni u 4 skupine (geomorfometrijski, pedološki, klimatski i hidrološki) te ograničavajućih faktora unutar programa *ArcMap 10.1*. Model je izrađen 5-metarskom prostornom rezolucijom, veličina piksela je 5 m svih rasterskih kriterija u projekciji HTRS96/TM zasnovanoj na GRS80 elipsoidu (Sl. 29). Metoda AHP-a je primijenjena u određivanju težinskih koeficijenata vrednovanih kriterija. Svi kriteriji su standardizirani prema FAO klasama pogodnosti gdje je za svaku klasu određen raspon vrijednosti svakog kriterija (Tablica 5). Izrađeni model klasificiran je u 5 klasa prema FAO metodologiji (FAO, 1976), stoga su rezultati istraživanja izneseni za svaku klasu posebno. Ostale površine modela pogodnosti poljoprivrednog zemljišta zauzimaju ograničavajući faktori koji zauzimaju površinu od 183 053,52 ha, odnosno 44,18 % površine Osječko-baranjske županije (Tablica 11). Ograničavajući faktori su opisani u poglavlju *Određivanje kriterija*.



Slika 33. Model pogodnosti s ograničavajućim faktorima

Model pogodnosti poljoprivrednog zemljišta za uzgoj ječma naredbom *Raster to polygon* (*Conversion tools*) pretvoren je iz rasterskog u vektorski sloj te mu je izračunata površina u hektarima. Nakon toga, naredbom *Dissolve* (*Data Management tools*) izračunate su površine klasa pogodnosti i površine ograničavajućih faktora unutar modela (Tablica 11).

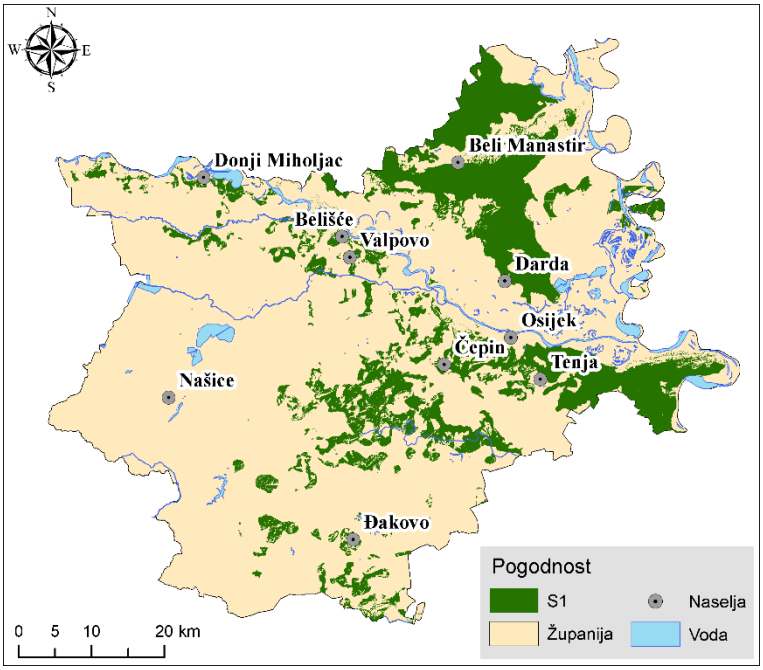
Tablica 11. Površina i udio klasa modela pogodnosti Osječko-baranjske županije

Klasa	Površina (ha)	Udio (%)
S1	64703,76	15,62
S2	122557,13	29,58
S3	28072,76	6,78
N1	14502,74	3,50
N2	1405,57	0,34
Ograničavajući faktori	183053,52	44,18
Ukupno	414295,48	100

6.1. VRLO POGODNA - S1

Klasa pogodnosti S1 predstavlja najpogodnije područje za uzgoj ječma te se prostire na površini od 64 703,76 ha, odnosno 15,62 % površine Osječko-baranjske županije (Tablica

11). To su u pravilu zemljišta koja nemaju specifična ograničenja ili su ta ograničenja relativno mala te neće utjecati na produktivnost tog zemljišta (Tablica 6). Najveća područja klase S1 nalaze se uz rijeku Vuku, prateći njen tok, na istočnom dijelu županije južno od rijeke Drave (Bijelo Brdo, Dalj, Aljmaš, Erdut), središnjem (Bilje i Čeminac) i sjevernom dijelu Baranje (sjeverno i južno od Banskog brda) uz granicu s Mađarskom (Beli Manastir, Kneževo, Pletovac) (Sl. 34). Razlog tomu je što se na tim područjima nalaze tla visoke kvalitete koje po svojim teksturama i kiselosti pripada S1 klasama pogodnosti: aluvijalna tla, černozem na praporu semiglejni i tipični te eutrično smeđe tlo (Tablica 5). S obzirom na to da pedološki kriteriji imaju najveće težinske koeficijente (Tablica 7) jasno je da su sve klase pogodnosti najviše uvjetovane njima. Što se tiče geomorfometrijskih kriterija, prostori na kojima se nalazi klasa S1 su zaravnjeni prostori, bez izraženih nagiba, no jasno se vide isprekidane strukture klase S1 uzrokovane naglijim promjenama nagiba (sjeveroistočni dio Banskog brda). Iste strukture isprekidanosti su vidljive na manjim dijelovima klase S1 na prostoru krndijskog osojnog pobrđa koje su također uvjetovane promjenama u nagibu, ali i većim potencijalom za pojavu erozije. Također, klase visoke pogodnosti pojavljuju se i na manjim površinama, lokalno izraženim, koje karakteriziraju prostore južno od Đakova, širu okolicu Belišća i Valpova te širu okolicu Donjeg Miholjca (Sl. 34).



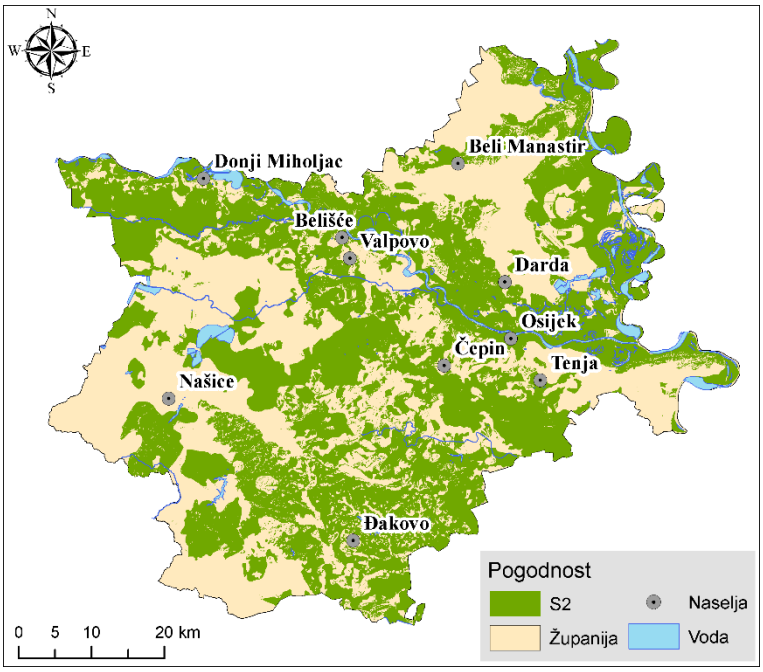
Slika 34. Karta S1 klase modela pogodnosti

Na području klasa visoke pogodnosti uzgaja se 1 395,95 ha ječma, odnosno 27,93 % ukupnih površina na kojima je zasijan ječam u Osječko-baranjskoj županiji (Tablica 9).

Najvećim se dijelom te parcele nalaze na prostorima središnje Baranje (Darda i Novi Čeminac), okolice Čepina, jugoistočnog dijela Osijeka, istočno od Valpova te zapadno od Donjeg Miholjca.

6.2. UMJERENO POGODNA – S2

Klasa pogodnosti S2 predstavlja najzastupljeniju i najrasprostranjeniju klasu pogodnosti poljoprivrednog zemljišta za uzgoj ječma Osječko-baranjske županije, a prostire se na 122 557,13 ha, odnosno 29,58 % županije (Tablica 11). To su zemljišta koja imaju umjerena ograničenja za trajnu uporabu i kao takva će smanjiti produktivnost tla, no ona neće biti previše izražena (Tablica 6). Rasprostranjena u svim dijelovima županije, najzastupljenije površine nalaze se neposredno uz tokove rijeka Drave, Dunava i Karašice te u središnjem dijelu županije (prostor općine Koška) (Sl. 35). S obzirom na to da su na tim područjima gemorfometrijski i klimatski kriteriji vrlo pogodni, pedološki kriteriji su izraženije utjecali na pogodnost tla. Razlog tomu je što na tim područjima dolazi do preklapanja tala klasa S2 i S3 te su ti prostori karakterizirani slabijom, odnosno nepotpunom ocjeditošću (Tablica 5). Jasno su vidljive ispresijecane teksture klase S2 s klasom S1 koje su uzrokovane izraženijim ograničavanjem geomorfometrijskih kriterija (nagiba i ekspozicije) na prostoru Banskog brda i erdutskog gorja te na pojedinim dijelovima krndijskog osojnog pobrđa. Što se tiče krndijskog osojnog pobrđa, klase S2 se nalaze na prostorima gdje su kiselost i tekstura vrlo pogodne, no lošiji tip tla (pseudoglej obronačni) i veći nagibi su dovoljno izraženi (Sl. 35). Bitno izražena površina klase S2 nalazi se na prostoru južno od Tenje (naselje Silaš) koje je uzrokovano slabijom ocjeditošću i lošijim vrijednostima pH te djelomično hidromelioriranim močvarno glejnim tlom. Također, južni dio županije (okolica Đakova) karakteriziran je klasom S2 koja se djelomično preklapa s klasom S3 zbog lošijih pH vrijednosti.



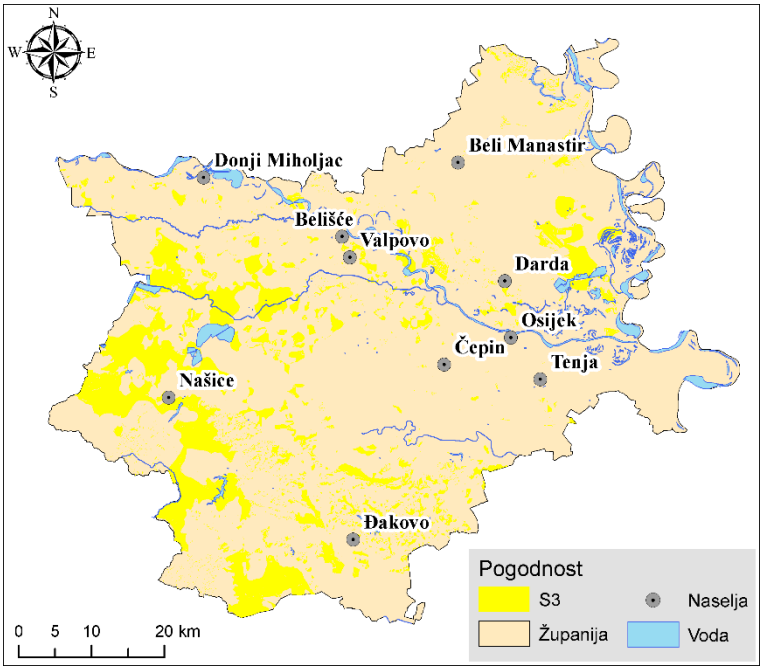
Slika 35. Karta S2 klase modela pogodnosti

Na području klase umjerene pogodnosti zasijano je 2 843,81 ha ječma, odnosno 56,89 % ukupno zasijanog ječma u Osječko-baranjskoj županiji prema dostavljenim podacima APPRRR-a (Tablica 9). Te se parcele najvećim dijelom nalaze u Baranji, na prostoru općina Kneževi Vinogradi, Darde i Jagodnjak te općinama Donji Miholjac, Viljevo, Čepin i Antunovac.

6.3. MARGINALNO POGODNA – S3

Klasa S3, marginalno pogodna, predstavlja zemljišta na kojima je uzgoj određene kulture, u ovom slučaju ječma, marginalno opravdan, tj. jedva isplativ (Tablica 6). Klasa S3 obuhvaća 28 072,76 ha, odnosno 6,78 % teritorija Osječko-baranjske županije (Tablica 11). To su zemljišta na kojima je potrebno vršiti znatnije prihranjivanje i voditi veću brigu o zasijanim kulturama. Zbog većih troškova uzgoja, marginalno je opravdana uporaba takvih zemljišta. Klasa S3 najvećim se dijelom rasprostire na zapadnom dijelu županije (općine Magadenovac i Đurđenovac), prostoru krndijskog osojnog pobrđa, južnom dijelu županije (općina Trnava) te u istočnom dijelu Baranje (općine Bilje i Kneževi Vinogradi) (Sl. 36). U istočnom dijelu Baranje, neposredno uz Park prirode Kopački Rit, marginalno pogodna klasa uvjetovana je slabije pogodnim pedološkim kriterijima. Iako su iznimno pogodni geomorfološki i klimatski kriteriji, najveći problem predstavljaju djelomično kisela tla

(naselja Sokolovac, Kozjak, Podunavlje) i nepotpuna do slaba ocjeditost tla. Također na tim prostorima se nalazi močvarno glejno, djelomično hidromeliorirano tlo koje pripada S3 klasi pogodnosti (Tablica 5). Kao što je već navedeno, šira okolica Đakova karakterizirana je isprekidanim vrijednostima klase S2 i S3. Iako je to prostor tala koja pripadaju S2 klasama (lesivirano na praporu), zbog veće kiselosti tla i djelomično slabe ocjeditosti, dolazi do pojave marginalno pogodnih klasa. Prostor krndijskog osojnog pobrđa karakteriziran je tlom pseudoglej obronačni kojeg karakterizira pogodna tekstura (praškasto ilovasta) i dobra ocjeditost, no to je tlo slabije pogodno (Tablica 5). Na tom prostoru klasa S3 okarakterizirana je umjerenim podložnostima erodiranju materija, nagibima 8 – 16 % te relativno kiselim tlima. Također, to je prostor gdje dolazi do pojave nepogodnih klasa, no granice klasa jasno su izražene. Za razliku od krndijskog osojnog pobrđa, prostor zapadnog dijela županije karakteriziran je klasama S3, slično kao i na prostoru Baranje. Naime, tipovi tla su pseudoglej-glej, djelomično hidromeliorirani i močvarno glejno, djelomično hidromeliorirani, pogodne teksture, no zbog velike kiselosti i loše ocjeditosti, ta područja pripadaju marginalno pogodnim klasama. Pojava manjih, lokaliziranih sastojina klasa S3 na prostoru sjevernog dijela Baranje i sjeverozapadnog dijela županije (Sl. 36), uzrokovana je slabom ocjeditosti, lošim pH vrijednostima (zakiseljena tla) i močvarno glejnim, djelomično hidromelioriranim tlima (Tablica 5).

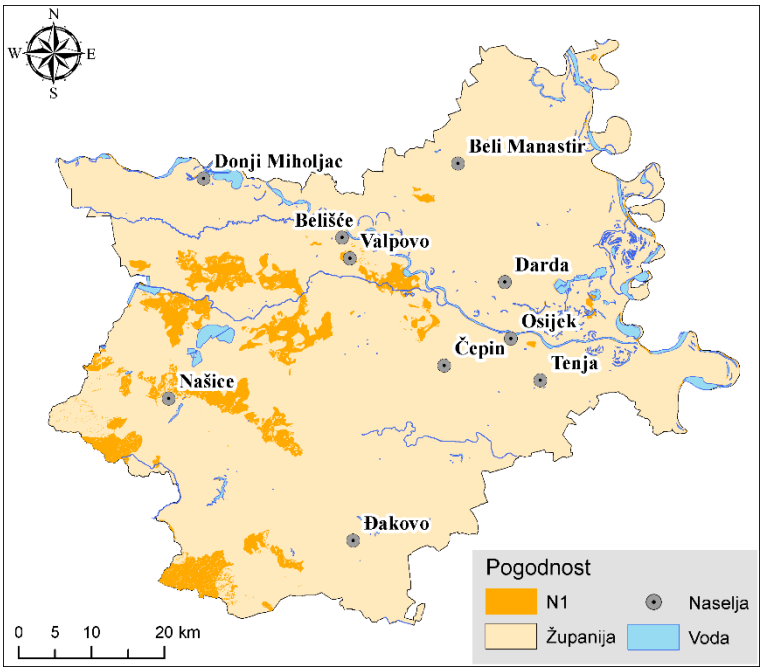


Slika 36. Karta S3 klase modela pogodnosti

Na području marginalno pogodnih klasa zasijano je 437,41 ha, odnosno 8,75 % ukupne površine zasijane ječmom na prostoru Osječko-baranjske županije (Tablica 9). Najvećim dijelom parcele zasijane ječmom u klasama S3 nalaze se na prostoru Baranje (općine Kneževi Vinogradi i Jagodnjak) te na zapadu županije (općine Našice i Đurđenovac). Ostale manje površine pojavljuju se samo kao rubni dijelovi većih parcela gdje dolazi do kontakta klasa S2 i S3, te S3 i N1.

6.4. TRENUTNO NEPOGODNA – N1

Klasa N1, trenutno nepogodna označava zemljišta koja trenutno imaju ograničenja koja onemogućavaju uporabu na određeni način, no ta ograničenja mogu biti otklonjena određenim agrotehnološkim zahvatima (Tablica 6). Na prostoru Osječko-baranjske županije, zemljišta klase N1 zauzimaju površinu od 14 502,74 ha, odnosno 3,50 % ukupne površine županije (Tablica 11). Zemljišta klase N1 najvećim se dijelom nalaze na zapadnom dijelu županije (općine Đurđenovac i Magadenovac), krndijskom osojnom pobrđu, sjeveroistočnim obroncima gore Dilj, središnjem dijelu županije (općine Koška, Marijanci), južnom dijelu općina Belišće i Valpovo te općine Petrijevci (Sl. 37). Na središnjem dijelu županije, klasa N1 uzrokovana nepotpunom i slabom ocjeditosti, kiselim tlima te lošom teksturom tla (praškasto glinasta), dok su geomorfološki i klimatski kriteriji pogodni. Tip tla je pseudoglej na zaravni te on pripada N1 klasi (Tablica 5). Prostor krndijskog osojnog pobrđa karakteriziran je nepogodnim tlom rendiza na laporu (flišu) ili mekim vapnencima (Tablica 5). Iako je na tim prostorima kiselost tla i nagib terena pogodan, presuđujući faktor bila je tekstura tla (glinasta) te potencijal erodiranju materijala koji je visok. Sjeveroistočni obronci gore Dilj odlikuju se dobrom ocjeditošću, pogodnim pH vrijednostima i klasama nagiba, no glavni razlozi zbog čega je to područje okarakterizirano kao N1 su visoki potencijal erozije, glinaste teksture te nepogodni tip tla (pseudoglej na zaravni i kiselo smeđe na klastitima). Na prostoru Baranje, pojava klasa N1 uvjetovana je nepogodnim tipom zemljišta (gitja), slabom i vrlo slabom ocjeditosti te glinastom teksturom. Ti prostori se uglavnom nalaze unutar Parka prirode Kopački Rit, stoga ni ne utječu na poljoprivredna zemljišta.



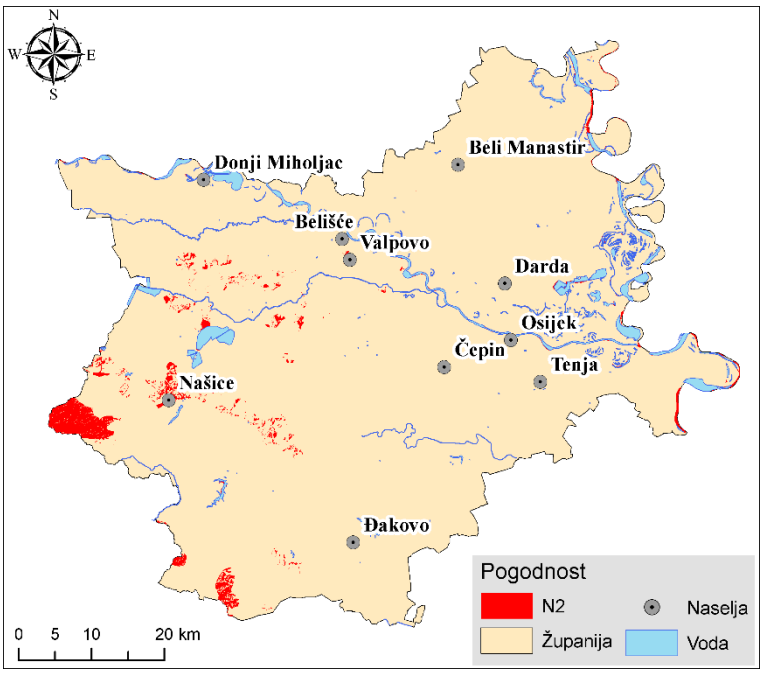
Slika 37. Karta N1 klase modela pogodnosti

Na području trenutno nepogodnih klasa N1 nalazi se 317,76 ha površina na kojima je zasijan ječam, odnosno na prostoru Osječko-baranjske županije 6,36 % ukupne površine je pod ječmom (Tablica 9). Te površine su u najvećoj mjeri dodirne točke između klasa pogodnosti (S2 i S3) i klase N1 na prostoru središnjeg dijela županije i jednog lokaliteta u Baranji (općina Jagodnjak).

6.5. TRAJNO NEPOGODNA – N2

Klasa N2, trajno nepogodno označava zemljišta koja imaju znatno izražena ograničenja te kao takva predstavljaju neuporabljiva zemljišta. Na prostoru Osječko-baranjske županije takvo zemljište zauzima 1 405,57 ha, odnosno 0,34 % (Tablica 11). To su najvećim dijelom prostori na zapadnom dijelu krndijskog osojnog pobrđa (okolica naselja Gornja Motičina i Gazije), sjeveroistočni obronci gore Dilj (okolica naselja Harkanovci Đakovački), okolica Našica i središnji dio županije (Sl. 38). Generalno gledano, prostori trajno nepogodnih klasa odlikuju se nepogodnim vrijednostima svih kriterija osim klimatoloških kriterija jer oni nisu fizički vezani uz tlo. Zapadni dio krndijskog osojnog pobrđa odlikuje se, u vidu pedoloških kriterija, manje pogodnim tipom tla (kiselo smeđe na metamorfitima i klastitima), glinastoj teksturi i kiselim tlima. Što se tiče geomorfometrijskih i hidroloških kriterija, na tom prostoru dolaze do izražaja izrazito nepogodne vrijednosti nagiba (24 – 30 %), orijentiranost

padina je pretežito sjeverna te je vrlo visok potencijal erodiranju materijala. Na prostoru sjeveroistočnih obronaka gore Dilj, klase trajno nepogodno N2 su isprekidane klasama N1. Na tom području hidrološki kriteriji su pogodni, ocjeditost je dobra, a erozijski potencijal je nizak te su u vezi s time i niske vrijednosti nagiba terena (S1 i S2 klase nagiba) (Tablica 5). S obzirom na to da u odnosu na geomorfometrijske ili hidrološke, pedološki kriteriji imaju znatno veće težinske koeficijente (Tablica 7), iznimno kisela tla (kiselo smeđe na klastitima) i glinasta tekstura su uvjetovali isprekidanost klasa N1 i N2. Prostor u okolici Našica te središnji dio županije odlikuju fragmentirane sastojine klasa N2 koje su uvjetovane slabom ocjeditosti, izrazito kiselim tlima, nepogodnom teksturom (praškasto glinasta) te u većim dijelovima sjevernom ekspozicijom. U ostatku županije prisutne su manje površine N2 klasa koje predstavljaju zamočvarene površine, povremene vodotoke ili vode općenito, no sve te površine ulaze u ograničavajuće faktore.



Slika 38. Karta N2 klase modela pogodnosti

Na području trajno nepogodnih klasa N2 nalazi se 3,96 ha, odnosno 0,08 % površina na kojima je zasijan ječam (Tablica 9). Te površine predstavljaju samo manje, rubne dijelove parcela na kojima je zasijan ječam. Na prostorima gdje dolazi do kontakta klase N2 s nekom drugom klasom, nema izraženijih površina.

7. RASPRAVA

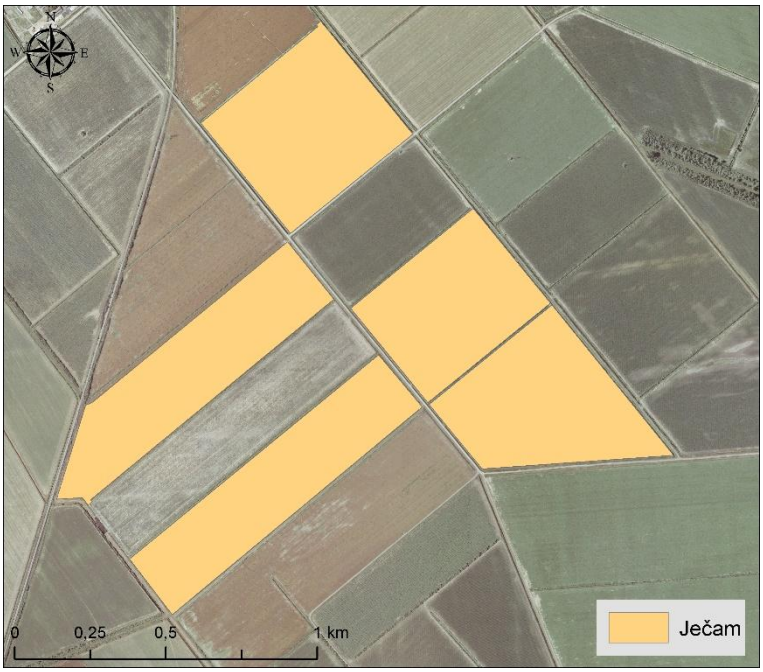
Model pogodnosti poljoprivrednog zemljišta za uzgoj ječma izrađen je metodom višekriterijskih GIS analiza na temelju 10 odabranih kriterija. Model je reklasificiran prema FAO klasama pogodnosti jer je ta metodologija široko korištena te zbog toga što većina autora preporučuje FAO klasifikaciju (Yohannes i Soromessa, 2018; Feizizadeh i Blaschke, 2013; Akinci i dr., 2013). Važnost ovakvih modela se nameće zbog sve veće potrebe za boljim i održivim upravljanjem zemljištem i potrebe da se potencijali zemljišnih resursa maksimalno iskoriste (Feizizadeh i Blaschke, 2013). Sve to je uvjetovano povećanjem svjetskog stanovništva koje dovodi do problema proizvodnje hrane, naseljenosti, prostorne distribucije resursa i slično (Akinci i dr., 2013; Feizizadeh i Blaschke, 2013). S obzirom na to, pridaje se velika važnost poljoprivrednim zemljištima zato što omogućuju ne samo proizvodnju hrane, nego i održavanje biološke raznolikosti, smanjenje koncentracije stakleničkih plinova, održavanje čiste vode i zraka i drugo (Ennaji i dr., 2018). Svako tlo ima svoje karakteristične zahtjeve kako bi se koristilo u određenu svrhu, stoga je potrebno analizirati zemljišta i prilagoditi način njihove uporabe kako bi se ta zemljišta koristila na održivi način (Ennaji i dr., 2018). Sve analize i procjene usmjerene su prema optimalnom korištenju zemljišta, što u velikoj mjeri olakšava poslove planiranja i upravljanja zemljištem. Analiza pogodnosti nekog zemljišta predstavlja proces određivanja pogodnosti tog zemljišta za određenu uporabu (poljoprivreda, šumarstvo, rekreacija) te razinu pogodnosti tog zemljišta (Akinci i dr., 2013). Najbitniji korak u takvim, višekriterijskim analizama pogodnosti je određivanje kriterija i pridodavanje težinskih koeficijenata tim kriterijima. Kako bi se izradila analiza pogodnosti nekog zemljišta, potrebno je uzeti u obzir sve ono što utječe na tu pogodnost, od ekonomskih i društvenih kriterija do fizičkih (Akinci i dr., 2013). Loše upravljanje poljoprivrednim zemljištem dovodi do degradacije tog zemljišta što predstavlja jedan od glavnih problema (Sarkar i dr., 2014; Akinci i dr., 2013; Yohannes i Soromessa, 2018). Zbog toga se javlja potreba za što točnijim procjenama zemljišta koje se temelje na višekriterijskim analizama kako bi se zemljištem upravljalo na održivi način (Feizizadeh i Blaschke, 2013). Također, Feizizadeh i Blaschke (2013) navode kako je poljoprivredna klasifikacija vitalna za planiranje i upravljanje poljoprivrednim zemljištem te da se takve analize već koriste za upravljanje zemljištem u Iranu. S obzirom na to da je u posljednjih 20-tak godina došlo do rapidnog razvoja tehnologija i integracije GIS-a u poljoprivredu (Rapčan i dr., 2018), kao rješenje izradi višekriterijskih analiza pogodnosti za upravljanje poljoprivrednim zemljištem, nameće se upotreba GIS tehnologija (Kazemi i Akinci, 2018;

Mustafa i dr., 2011). Svi navedeni autori (Tablica 4) koristili su se GIS metodama u izrađivanju višekriterijskih modela pogodnosti u svojim radovima. U vezi s time, jasno su vidljive podudarnosti u određivanju kriterija i njihovom vrednovanju (Tablica 4). Također, bitno je naglasiti da se većina autora, za određivanje težinskih koeficijenata koristi AHP metodom te za klasificiranje modela FAO klasifikacijom kako je navedeno u poglavlju *Prethodna istraživanja*.

Pri određivanju kriterija, najveći težinski koeficijenti su pridodani pedološkim kriterijima (Tablica 7) zbog toga što ječam ne podnosi tla slabije kvalitete, kisela ili slabo ocjedita tla (Gagro, 1997), kako je navedeno u poglavlju *Ječam*. Također, u drugim radovima, pedološki kriteriji poput pH, dubine tla, tipa tla ili teksture tla imaju najveće težinske koeficijente (Ennaji i dr., 2018; Sarkar i dr., 2014; Akinci i dr., 2013; Ahamed i dr., 2000). Za razliku od njih, ostali radovi pridodaju najveću važnost geomorfometrijskim kriterijima poput nagiba ili nadmorske visine, no i dalje su kriteriji poput dubine tla i teksture relativno blizu u pogledu težinskih koeficijenata (Feizizadeh i Blaschke, 2013; Yohannes i Soromessa, 2018). Razlog tomu je to što su područja istraživanja izrazito vertikalno raščlanjena. Iz navedenog se može zaključiti da su pedološki kriteriji (pH, dubina tla, tip tla i tekstura tla) najviše vrednovani što se tiče pogodnosti poljoprivrednog zemljišta.

Klase pogodnosti izrađenog modela najviše su uvjetovane pedološkim kriterijima, odnosno kriterijem tipa tla zbog toga što su sve ostale skupine kriterija relativno pogodne za prostor cijele županije. Gledano kroz klase pogodnosti i raspone vrijednosti kriterija po klasama (Tablica 5), može se zaključiti da kriteriji temperature, oborina i nadmorske visine nemaju značajniju ulogu jer su gotovo cijelom svojom površinom predstavljeni jednom klasom. Kriteriji nagiba, erozijskog potencijala i ocjeditosti su više izraženi samo na prostoru krndijskog osojnog pobrđa i Banovog brda jer su uvjetovani vertikalnom raščlanjenošću terena. Na prostoru Banovog brda, ta je izraženost kriterija relativno mala, stoga nema većih promjena klasa pogodnosti. Budući da je taj dio pedološki najizraženiji, pogodan tip tla, pH vrijednosti i tekstura tla, dolazi do izmjena klasa S1 i S2. Za razliku od Banovog brda, prostor krndijskog osojnog pobrđa geomorfološki je izraženiji, veći su nagibi terena što uzrokuje veći erozijski potencijal (Domazetović, 2018). Također, taj se prostor odlikuje kiselim tlima loše teksture te stoga dolazi do izmjena pogodnih i nepogodnih klasa. Prostor središnjeg dijela županije odlikuje se izmjenom klasa S3 i N1. Središnji dio županije je karakterističan zbog toga što prostori N1 klase imaju bolju ocjeditost nego prostori klase S3, no kriterij teksture tla je bio presuđujući faktor u generiranju klasa pogodnosti jer ima veći težinski koeficijent. Na

prostoru Baranje (Park prirode Kopački Rit) klasa S3 je uvjetovana slabom ocjeditošću i nižim pH vrijednostima, iako je tip tla S2 klase pogodnosti. Na temelju toga se može zaključiti da kriterij tipa tla, iako ima najveći težinski koeficijent, ne mora nužno biti presuđujući faktor generirane klase.



Slika 39. Primjer parcela pod ječmom na DOF-u

U prilogu svega navedenog, može se potvrditi prva hipoteza. Površine koje su zasijane ječmom nalaze se preko 50 % svoje površine u klasama pogodnosti, odnosno u klasi S1, S2 i S3 se nalazi 93,57 % ukupne površine zasijane ječmom, tj. 4 677,17 ha (Tablica 9).

Druga hipoteza je također potvrđena, metodom izračuna zdravlja vegetacije, moguće je detektirati usjeve ječma. Izrađeni NDVI indeks se preklapa s površinama na kojima je zasijan ječam, što potvrđuje ovu hipotezu.

8. ZAKLJUČAK

Za izradu modela pogodnosti poljoprivrednog zemljišta za uzgoj ječma, geoprostorne tehnologije i višekriterijske analize pokazale su se kao izvrsne metode u izradi ovakvog modela. Kako zadnjih godina dolazi do sve bržeg razvoja tehnologija, vidljivo je da poljoprivreda postaje gotovo nezamisliva bez upotrebe tih tehnologija. Uvijek se teži postići što veći i kvalitetniji prinos u poljoprivredi, a to se postiže jedino velikim trudom i naporom te novim spoznajama koje donose aktualni znanstveno-istraživački radovi. Danas nove tehnologije omogućuju brzo prikupljanje, pohranjivanje, analiziranje, vizualiziranje i interpretaciju geopodataka koji mogu biti dostupni svima. Upravo se zbog toga javlja potreba za primjenom tih tehnologija kako bi se u konačnici stvorio proizvod koji će biti neupitne kvalitete i koji će moći konkurirati na tržištu najvećim i najjačim brendovima.

Zbog sve prepoznatljivije isplativosti uzgoja i sve veća potražnje u pivarskoj i prehrambenoj industriji, ječam se svrstava u isplative poljoprivredne kulture. Uloženi znanstveni napori na prostoru Osječko-baranjske županije i izrada interpolacijske baze podataka ukazuju na to da postoje modeli koji će pomoći poljoprivrednicima u donošenju odluka i upravljanju svojim gospodarstvima. Također, potrebno je i ostvariti suradnju između lokalne samouprave, poljoprivrednog i znanstveno-istraživačkog sektora kako bi se poljoprivreda u Hrvatskoj podigla na višu razinu i time omogućila konkurentnost na europskom tržištu.

Izrada ovoga diplomskog rada ukazuje na visoku pogodnost uzgoja ječma na prostoru Osječko-baranjske županije. Razlog tomu je što velikim dijelom županije nema toliko velikih ograničenja koja bi sprječavala uzgoj ječma. Vrlo plodna tla dobre teksture i ocjeditosti pogoduju uzgoju poljoprivrednih kultura na zaravnjenim i blago nagnutim terenima uz pogodne temperature i oborine. Naravno, uvijek postoji prostor za unaprjeđenje koje se može postići agrotehničkim zahvatima. Višekriterijska metoda AHP pokazala se idealnom za određivanje težinskih koeficijenata jer omogućuje usporedbu numeričkih i nenumeričkih vrijednosti. S obzirom na to da pogodnost zemljišta predstavlja stupanj prikladnosti korištenja tog zemljišta, FAO klasifikacija pogodnosti se pokazala korisnom metodologijom klasifikacije modela jer omogućuje grupiranje različitih zemljišta prema njihovim prikladnostima za određenu uporabu.

9. LITERATURA

Akinci H., Özapl A.Y. i Turgut B. (2013), *Agricultural land use suitability analysis using GIS and AHP technique*, Computers and Electronics in Agriculture, br. 93, str. 71-82

Ahamed T.R. dr. (2000), *GIS-based fuzzy membership model for crop-land suitability analysis*, Agricultural Systems, br. 63, str. 75-95

Badr A. i dr. (2000), *On the Origin and Domestication History of Barley (Hordeum vulgare)*, Molecular Biology and Evolution, br. 17(4), str. 499-510

Bodunović M. i dr. (1997), *Namjenska pedološka karta Republike Hrvatske i njena uporaba*, Agronomski glasnik, br. 5-6

Creswell J.W. (2013), *Research design: qualitative, quantitative, and mixed methods*, SAGE Publications, Thousand Oaks

Crnčan A. i dr. (2016), *Primjena metode višekriterijskog odlučivanja u poljoprivrednoj proizvodnji*, Krmiva, br. 58, str. 33-40

Domazetović F. (2018), *Kvantitativne analize jaruga na prostoru otoka Paga korištenjem modela visoke rezolucije*, diplomski rad, Sveučilište u Zadru

Državni zavod za statistiku (2018), *Poljoprivredna prozvodnja u 2017.*, Statističko izvješće 1610, Zagreb

Ennaji W. i dr. (2018), *GIS-based multi-criteria land suitability analysis for sustainable agriculture in the northeast area of Tadla plain (Morocco)*, Journal of Earth System Science, br. 127(79), str. 1-14

FAO (1976), *Land evaluation in Europe*, Soils bulletin 29, Food and Agricultural Organization of United Nations, Rim

Feizizadeh B., Blaschke T. (2013), *Land suitability analysis for Tabriz County, Iran: a multi-criteria evaluation approach using GIS*, Journal of Environmental Planning and Managment, br. 53(1), str.1-23

Gagro M. (1997), *Ratarstvo obiteljskog gospodarstva: žitarice i zrnate mahunarke*, Hrvatsko agronomsko društvo, Zgareb

Grubišić F. (2014), *Uloga geoprostorne znanosti i tehnologije za razvoj održive budućnosti*, Sveučilište u Zagrebu, Ekscentar, br.17, str. 77-81

Hornsey I.S. (2003), *A history of beer and brewing*, The Royal Society of Chemistry, Cambridge

Husnjak S. (2014), *Sistematika tala Hrvatske*, Hrvatska sveučilišna naklada, Zagreb

Husnjak S., Bensa A. (2018), *Pogodnost poljoprivrednog zemljišta za navodnjavanje u agroregijama Hrvatske*, Hrvatske vode, br. 105, str. 157-180

Jurišić M. i dr. (2015), *Tehnički i tehnološki aspekti pri zaštiti bilja u sustavu precizne poljoprivrede*, Poljoprivredni fakultet Osijek, Poljoprivreda, br.21, str. 75-81

Kazemi H., Akinci H. (2018), *A land suitability model for rainfed farming by Multi-criteria Decision-making Analysis (MCDA) and Geographic Information System (GIS)*, Ecological Engineering, br. 116, str. 1-6

Lalić A. i dr. (2007), *Analiza uroda zrna i pivarske kakvoće ječma u Republici Hrvatskoj*, Poljoprivredni institut Osijek, Sjemenarstvo, br.24(3-4), str. 177-185

Magaš D. (2013), *Geografija Hrvatske*, Sveučilište u Zadru, Meridijan, Zadar

Malczewski J. (2004), *GIS-based land-use suitability analysis: a critical overview*, Progress in Planning, br. 62, str. 3-65

Malczewski J., Rinner C. (2015), *Multicriteria Decision Analysis in Geographic Information System*, Springer

Manić E., Gajović V. i Popović S. (2016), *Geografski informacioni sistemi u poljoprivredi*, Sveučilište u Beogradu, Ekonomske ideje i praksa, br.21, str. 45-58

Marić I. i dr. (2019), *Application of intergrated geo-technologies in agricultural land planing and managment – a case study of agro estate „Baštica“*, Izgradnja, br. 72, str. 576-586

Martinčić J., Kolak I. (1993), *Ječam – Hordeum Vulgare L. Conv. Distichum, sirovina za potrebe industrije slada i piva*, Poljoprivredni institut Osijek, Sjemenarstvo, br.10(3-4), str. 169-172

Mustafa A.A. i dr. (2011), *Land suitability Analysis for Different Crops: A Multi Criteria Decision Making Approach using Remote Sensing and GIS*, Researcher, br.3, str. 61-84

Narodne Novine (1994), *Zakon o poljoprivrednom zemljištu*, Zagreb

Odak I., Tomić H. i Mastelić Ivić S. (2017), *Vrednovanje fragmentacije poljoprivrednih zemljišta*, Geodetski list, br.3, str. 215-232

Pierce F.J., Clay D. (2007), *GIS Aplications in Agriculture*, CRC Press, Boca Raton

Rapčan I. i dr. (2018), *Gnojidba pšenice u sustavu precizne poljoprivrede*, Agronomski glasnik, Hrvatsko agronomsko društvo, Zagreb, br.3, srt. 163-172

Rosso A.M. (2013), *Beer and wine in antiquity: beneficial remedy or punishment imposed by the Gods?*, Acta medico-historica Adriatica, br.10(2), str. 237-262

Saaty T.L. (1990), *How to make a decision: The Analytic Hierarchy Process*, European Journal of Operational Research, br.48, str. 9-26

Saaty T.L. (2008), *Decision making with the analytic hierarchy process*, International Journal of Services Science, br.1(1), str. 83-98

Sarkar A., Ghosh A. i Banki P. (2014), *Multi-criteria land evaluation for suitability analysis of wheat: a case study of a watershed in eastern plateau region, India*, Geo-spatial Information Science, br. 17(2), str. 119-128

Sekulić M. (2019), *Multi-Criteria GIS modelling for optimal alignment of roadway by-passes in the Tlokweng Planning Area, Botswana*, dipomski rad, Sveučilište u Lundu

Setiawan A., Sediyono E. i Moekoe D.A.L. (2014), *Application of AHP Method in Derermining Priorities of Conversion of Unusedland of Food Land in Minahasa Tenggara*, International Journal od Computer Applications, br.89 (8), str. 37-44

Sys C., Van Ranst E. i Debaveye J. (1991) *Land Evaluation Part 1: Principles in land evaluation and crop production calculations*, Agricultural Publications, br.7

Sys C. i dr. (1993), *Land evaluation Part 3: Crop Requirements*, Agricultural publications, br.7

Šiljeg A., Barada M. i Marić I. (2018), *Digitalno modeliranje reljefa*, Alfa, Zagreb

Triantaphyllou E. (2000), *Multi-Criteria Decision Making Methods: A comparative Study*, Applied Optimization, br.44, Springer, Boston

Vukadinović V. i dr. (2014), *Model interpretacijske baze zemljišnih resursa Osječko-baranjske županije*, Agronomski glasnik, br. 76 (1-2), str. 29-42

Vukadinović V., Vukadinović V. (2018), *Zemljišni rasursi*, Poljoprivredni faklutet u Osijeku

Yohannes H., Soromessa T. (2018), *Land suitability assessment for majr crops by using GIS-based multi-criteria approach in Andit Tid watershed, Ethiopia*, Cogent Food & Agriculture, br. 4

Zhang C., Kovacs J.M. (2012), *The application of small unmanned aerial systems for precision agriculture: a review*, Precision Agriculture, br.13, str. 693-712

Zhang J. i dr. (2015), *GIS based land suitability assessment for tobaco production using AHP and fuzzy set in Shandong province of China*, Computers and Electronics in Agriculture, br. 114, str. 202-211

10. IZVORI

URL 1 http://pinova.hr/hr_HR/baza-znanja/ratarstvo/jecam (10.04.2019.)

URL 2 http://pinova.hr/hr_HR/baza-znanja/ratarstvo/jecam/agroekoloski-uvjeti-uzgoja-jecma (10.04.2019.)

URL 3 http://pinova.hr/hr_HR/baza-znanja/ratarstvo/jecam/sortiment-jecma (10.04.2019.)

URL 4 https://www.dzs.hr/ (26.07.2019)

URL 5 https://hr.wikipedia.org/wiki/Osje%C4%8Dko_pivo (12.04.2019.)

URL 6 https://gisgeography.com/ndvi-normalized-difference-vegetation-index/ (19.07.2019.)

URL 7 https://en.wikipedia.org/wiki/Sentinel-2 (19.07.2019.)

URL 9 http://pedologija.com.hr/Zem_resursi.html (18.04.2019)

URL 10 https://earthexplorer.usgs.gov/ (20.04.2019.)

URL 11 https://www.apprrr.hr/agronet/ (06.08.2019.)

URL 12 http://www.bilje.hr/POLJOPRIVREDA/AgBase_1/HTM/jecam.htm (10.08.2019.)

URL 13 https://www.usgs.gov/land-resources/eros/phenology/science/ndvi-foundation-remote-sensing-phenology (22.08.2019.)

URL 14 https://en.wikipedia.org/wiki/Normalized_difference_vegetation_index (22.08.2019.)
URL 15 http://www.fao.org/3/x5310e/x5310e04.htm (03.09.2019.)
URL 16 https://www.projectsmart.co.uk/smart-goals.php (19.04.2019.)
URL 17 http://preglednik.arkod.hr (06.08.2019.)

11. POPIS GRAFIČKIH PRILOGA

Slika 1. Klas višerednog (lijevo) i dovrednog (desno) ječma
Slika 2. Nalazi iz egipatskih piramida o pripravi piva
Slika 3. Poljoprivredna gospodarstva prema veličini zemljišta
Slika 4. Prostorni smještaj Osječko-baranjske županije
Slika 5. Daljinska istraživanja u poljoprivredi
Slika 6. Primjer dronova korištenih u poljoprivredi
Slika 7. Princip spektralne analize zdravlja vegetacije
Slika 8. Primjer višekriterijske GIS analize pogodnosti zemljišta
Slika 9. FAO klasifikacija pogodnosti zemljišta
Slika 10. Karta korištenja zemljišta
Slika 11. Hipsometrijska karta
Slika 12. Karta nagiba padina (prema Tablica 5.)
Slika 13. Karta ekspozicije padina
Slika 14. Izvorna karta pH-KCl vrijednosti
Slika 15. Karta pH vrijednosti tla
Slika 16. Karta tipova tla
Slika 17. Karta teksture tla
Slika 18. Prosječna godišnja temperatura Osječko-baranjske županije
Slika 19. Prosječna godišnja količina oborina Osječko-baranjske županije
Slika 20. Karta ocjeditosti terena
Slika 21. Karta erozijskog potencijala Osječko-baranjske županije
Slika 22. Karta ograničavajućih faktora (Boolean pristup)
Slika 23. Standardizirani kriteriji nadmorske visine (lijevo) i ekspozicije (desno)
Slika 24. Standardizirani kriterij nagiba
Slika 25. Standardizirani kriteriji pH (lijevo) i tipa tla (desno)

Slika 26. Standardizirani kriterij teksture tla
Slika 27. Standardizirani kriteriji temperature (lijevo) i oborina (desno)
Slika 28. Standardizirani kriteriji ocjeditosti (lijevo) i erozije (desno)
Slika 29. Model pogodnosti poljoprivrednog zemljišta za uzgoj ječma
Slika 30. Karta parcela pod ječmom
Slika 31. NDVI indeks vegetacije
Slika 32. Reklasificirani NDVI indeks vegetacije
Slika 33. Model pogodnosti s ograničavajućim faktorima
Slika 34. Karta S1 klase modela pogodnosti
Slika 35. Karta S2 klase modela pogodnosti
Slika 36. Karta S3 klase modela pogodnosti
Slika 37. Karta N1 klase modela pogodnosti
Slika 38. Karta N2 klase modela pogodnosti
Slika 39. Primjer parcela pod ječmom na DOF-u

12. POPIS TABLIČNIH PRILOGA

Tablica 1. Sentinel 2 kanali
Tablica 2. Temeljna skala apsolutnog broja
Tablica 3. Indeks slučajne konzistencije
Tablica 4. Kriteriji za izradu modela
Tablica 5. Raspon pogodnosti po klasama
Tablica 6. Klase pogodnosti poljoprivrednog zemljišta
Tablica 7. Matrica „parne usporedbe“ intenziteta vrijednosti kriterija
Tablica 8. Zemljišni indeks FAO klasa pogodnosti
Tablica 9. Ukupna površina i udio parcela pod ječmom prema klasama pogodnosti
Tablica 10. Udio NDVI > 0,4 indeksa prema klasama pogodnosti
Tablica 11. Površina i udio klasa modela pogodnosti Osječko-baranjske županije

13. SAŽETAK

U ovom diplomskom radu izrađen je model pogodnosti poljoprivrednog zemljišta za uzgoj ječma na prostoru Osječko-baranjske županije. Model pogodnosti je rezultat višekriterijske GIS analize koja je izrađena na temelju 5 skupina kriterija: geomorfometrijskih (nadmorska visina, nagib i ekspozicija), pedoloških (tip tla, tekstura tla i kiselost tla), klimatskih (padaline, temperatura), hidroloških (ocjeditost i erozijski potencijal) te ograničavajućih faktora. Za određivanje težinskih koeficijenata koristila se AHP metoda koja omogućuje vrednovanje i usporedbu numeričkih i nenumeričkih vrijednosti. Pedološki kriteriji su imali najveće težinske koeficijente jer u najvećoj mjeri utječu na rast i razvoj poljoprivrednih kultura. Izrađeni model klasificiran je prema FAO klasifikaciji pogodnosti zemljišta u 5 klasa. S obzirom na to da se radi o pogodnosti poljoprivrednog zemljišta, izrađeni model je preklopljen s ograničavajućim faktorima koji čine 44,18 % površine županije. Model ukazuje na umjerenu pogodnost poljoprivrednog zemljišta, klasu S2 koja se prostire na 29,58 % površine Osječko-baranjske županije. Također, bitno je izražena visoka pogodnost, klasa S1 na području od 15,62 % površine županije, uglavnom na prostoru Baranje i istočnom dijelu županije. Glavni kriteriji koji su uvjetovali klase S1 i S2 bili su tip tla i kiselost tla. Klase nepogodnosti, N1 i N2 najviše se prostiru na zapadnom dijelu županije, prostoru oko Našica te krndijskom osojnom pobrđu. Razlog tome je što su ti prostori okarakterizirani kiselim tlima te velikim nagibima i nepogodnom teksturom tla.

Višekriterijske analize i AHP metoda pokazale su se kao izrazito dobre metoda u izradi ovakvog modela pogodnosti poljoprivrednog zemljišta. S obzirom na to da se ječam koristi u tekstilnoj, prehrambenoj i najviše u pivarskoj industriji, dolazi do povećane potražnje za tom kulturom, pogotovo na prostorima koji imaju dugačku pivarsku tradiciju, poput grada Osijeka. Stoga je potrebno ojačati suradnju između znanstvenog i poljoprivrednog sektora kako bi se poljoprivreda podigla na višu razinu i tako postala vodeća gospodarska grana u Republici Hrvatskoj.

14. SUMMARY

In this thesis, a model of the suitability of agricultural land for the cultivation of barley in the area of Osijek-Baranja County has been made. The suitability model is the result of a multi-criteria GIS analysis based on 5 criteria groups: topographical (altitude, slope, aspect), pedological (soil type, soil texture, soil acidity), climatic (precipitation, temperature), hydrological (drainage and erosion potential) and limiting factors. The AHP method was used to determine the weighting coefficients, which allows the numerical and non-numerical values to be evaluated and compared. The pedological criteria had the highest weight coefficients because they mostly influence the growth and development of agricultural crops. The model is classified according to the FAO classification of land suitability in 5 classes. Considering that it is the land suitability of agricultural land, the model created is overlapped with limiting factors that make up 44.18 % of the county area. The model indicates moderate suitability of agricultural land, class S2, which covers 29.58 % of the area of Osijek-Baranja County. In addition, a high suitability, class S1, in the area of 15.62 % of the area of the county, mainly in the area of Baranja and the eastern part of the county, was significantly expressed. The main criteria that conditioned classes S1 and S2 were soil type and soil acidity. The N1 and N2 unsiutable classes are most spread in the western part of the county, the area around Našice and the Krndija north hillside. The reason is that these areas are characterized by acid soils and high slopes and unfavorable soil texture.

Multi-criteria analyses and the AHP method have proven to be extremely good methods in developing this model of farmland suitability. Since barley is used in the textile, food and most of the brewing industries, there is an increased demand for this culture, especially in areas with a long brewing tradition, such as the city of Osijek. Therefore, it is necessary to intensify the cooperation between the scientific and agricultural sectors in order to raise agriculture to a higher level and thus become the leading industry in the Republic of Croatia.